

**TUGAS AKHIR - KS 141501**

**PERAMALAN JUMLAH KASUS DEMAM  
BERDARAH DI KABUPATEN MALANG  
MENGUNAKAN METODE SUPPORT VECTOR  
REGRESI**

**FORECASTING NUMBER OF DENGUE FEVER  
CASES IN MALANG DISTRICT USING SUPPORT  
VECTOR REGRESSION METHOD**

**MOCHAMAD HARUN HEKMATYAR**  
**NRP 05211440000162**

**Dosen Pembimbing**  
**Wiwik Anggraeni, S.Si., M.Kom**

**DEPARTEMEN SISTEM INFORMASI**  
**Fakultas Teknologi Informasi dan Komunikasi**  
**Institut Teknologi Sepuluh Nopember**  
**Surabaya 2019**





**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

TUGAS AKHIR - KS 141501

# **PERAMALAN JUMLAH KASUS DEMAM BERDARAH DI KABUPATEN MALANG MENGUNAKAN METODE SUPPORT VECTOR REGRESI**

**MOCHAMAD HARUN HEKMATYAR**  
NRP 05211440000162

Dosen Pembimbing  
Wiwik Anggraeni, S.Si., M.Kom.

DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2019





**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

FINAL PROJECT - KS 141501

# **FORECASTING NUMBER OF DENGUE FEVER CASES IN MALANG DISTRICT USING SUPPORT VECTOR REGRESSION METHOD**

**MOCHAMAD HARUN HEKMATYAR**  
NRP 05211440000162

Supervisors  
Wiwik Anggraeni, S.Si., M.Kom.

**INFORMATION SYSTEMS DEPARTMENT**  
Faculty of Information Technology and Communication  
Institut Teknologi Sepuluh Nopember  
Surabaya 2019



## LEMBAR PENGESAHAN

### PERAMALAN JUMLAH KASUS DEMAM BERDARAH DI KABUPATEN MALANG MENGGUNAKAN METODE SUPPORT VECTOR REGRESI

#### TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat Memperoleh  
Gelar Sarjana Komputer  
pada

Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember

Oleh :

**MOCHAMAD HARUN HEKMATYAR**

NRP. 05211440000162

Surabaya, Januari 2019

**KEPALA  
DEPARTEMEN SISTEM INFORMASI**



**Mahendrawati ER, S.T., M.Sc., Ph.D**

NIP. 19761011 200604 2 001





## LEMBAR PERSETUJUAN

### PERAMALAN JUMLAH KASUS DEMAM BERDARAH DI KABUPATEN MALANG MENGGUNAKAN METODE SUPPORT VECTOR REGRESI

#### TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat Memperoleh  
Gelar Sarjana Komputer  
pada  
Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember

Oleh :

**MOCHAMAD HARUN HEKMATYAR**

NRP. 05211440000162

Disetujui oleh Tim Penguji : Tanggal Ujian : Januari 2019  
Periode Wisuda : Maret 2019

**Wiwik Anggraeni, S.Si, M.Kom.**

(Pembimbing I)

**Edwin Riksakomara, S.Kom, MT.**

(Penguji I)

**Faizal Mahananto, S.Kom., M.Eng., Ph.D. (Penguji II)**





# **PERAMALAN JUMLAH KASUS DEMAM BERDARAH DI KABUPATEN MALANG MENGGUNAKAN METODE SUPPORT VECTOR REGRESI**

**Nama Mahasiswa : Mochamad Harun Hekmatyar**  
**NRP : 05211440000162**  
**Departemen : SISTEM INFORMASI FTIK-ITS**  
**Dosen Pembimbing 1 : Wiwik Anggraeni, S.Si., M.Kom.**  
**Dosen Pembimbing 2 : -**

## **ABSTRAK**

*Demam berdarah dengue (DBD) adalah suatu penyakit yang disebabkan oleh infeksi virus dengue. DBD adalah penyakit akut dengan manifestasi klinis perdarahan yang menimbulkan syok yang berujung kematian. Penyakit Demam Berdarah adalah endemik yang muncul sepanjang tahun, terutama saat musim penghujan ketika nyamuk dalam kondisi optimal untuk berkembang biak, sehingga dapat dibilang persebaran nyamuk demam berdarah bergantung dengan iklim.*

*Pada Tahun 2016, Kabupaten Malang termasuk dalam 3 besar kabupaten dengan jumlah kasus Demam Berdarah Tertinggi di Jawa Timur, oleh karena itu diperlukan peramalan yang akurat agar Dinas Kesehatan Kabupaten Malang dapat mencegah dan mengantisipasi kasus demam berdarah lebih dini. Data hasil peramalan bisa digunakan untuk perencanaan pelayanan medis, seperti penanganan tepat waktu terhadap pasien dan ketersediaan obat-obatan yang dibutuhkan di masa yang akan datang. Tugas akhir ini bertujuan untuk melakukan peramalan kasus demam berdarah di Kabupaten Malang dengan menggunakan metode Suport Vector Regresi (SVR). Dasar pemikiran dari SVR adalah untuk memetakan set data ke ruang fitur dimensi tinggi non-linear dan menyelesaikan permasalahan regresi dalam ruang fitur dimensi ini. Berdasarkan keunggulan dalam kapasitas menangani high dimensional data, SVR menjadi algoritma yang populer dalam memecahkan masalah peramalan.*

*Hasil peramalan yang dilakukan diharapkan memiliki tingkat akurasi yang cukup tinggi dan bisa membantu Dinas Kesehatan Kabupaten Malang dalam menangani kasus demam berdarah di masa mendatang seperti persiapan obat – obatan, pelayanan pasien agar dapat mengurangi korban jiwa yang disebabkan oleh wabah ini.*

*Model Suport Vektor Regresi dapat digunakan untuk meramalkan jumlah kasus demam berdarah dikarenakan memiliki nilai error yang cukup dapat diterima.*

*Hasil peramalan jumlah kasus demam berdarah di beberapa desa Kabupaten Malang pada periode selanjutnya memiliki nilai rata-rata SMAPE : 27.69%, rata-rata MAD : 0.33 dan rata-rata MSE : 0.44. Hasil peramalan ini dapat dibilang cukup baik*

***Kata Kunci : Peramalan, Demam Berdarah,Support Vector Regresi***

# FORECASTING NUMBER OF DENGUE FEVER CASES IN MALANG DISTRICT USING SUPPORT VECTOR REGRESSION METHOD

**Name** : Mochamad Harun Hekmatyar  
**NRP** : 05211440000162  
**Department** : SISTEM INFORMASI FTIK-ITS  
**Supervisor 1** : Wiwik Anggraeni, S.Si., M.Kom.  
**Supervisor 2** : -

## ABSTRACT

*Dengue hemorrhagic fever (DHF) is a disease caused by dengue virus infection. DHF is an acute disease with clinical manifestations of bleeding that cause shock which leads to death. Dengue Fever is an endemic that occurs throughout the year, especially during the rainy season when mosquitoes are in optimal conditions for breeding, so it can be said that the spread of dengue mosquitoes depends on the climate.*

*In 2016, Malang Regency was included in the top 3 districts with the highest number of Dengue Fever cases in East Java, therefore accurate forecasting was needed so that the Malang District Health Office could prevent and anticipate cases of dengue fever earlier. Data forecasting results can be used for planning medical services, such as timely handling of patients and the availability of medicines needed in the future. This final project aims to forecast dengue fever cases in Malang Regency by using the Support Vector Regression (SVR) method. The rationale for SVR is to map data sets to non-linear high-dimensional feature spaces and solve regression problems in this dimensional feature space. Based on excellence in capacity to handle high dimensional data, SVR is a popular algorithm in solving forecasting problems.*

*The forecasting results carried out are expected to have a fairly high level of accuracy and can help the Malang District Health Office in dealing with dengue cases in the future such*

*as preparation of medicines, patient services in order to reduce the fatalities caused by this outbreak.*

*Vector Support Model Regression can be used to predict the number of bleeding deaths because it has a fairly acceptable error value.*

*The results of forecasting the number of dengue fever cases in several villages in Malang Regency in the following period had an average value of SMAPE: 27.69%, the average MAD: 0.33 and the average MSE: 0.44. This forecasting result is considered good enough.*

***Keyword : Forecasting, Dengue hemorrhagic fever, Suport Vector Regression***

## KATA PENGANTAR

Puji syukur penulis panjatkan kehadiran Tuhan Yang Maha Esa atas segala berkat dan rahmat-Nya penulis dapat menyelesaikan buku tugas akhir dengan judul **“PERAMALAN JUMLAH KASUS DEMAM BERDARAH DI KABUPATEN MALANG MENGGUNAKAN METODE SUPPORT VECTOR REGRESI”** yang merupakan salah satu syarat kelulusan pada Departemen Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Secara khusus penulis akan menyampaikan ucapan terima kasih yang sedalam-dalamnya kepada:

1. Tuhan yang Maha Esa yang telah memberikan segala kebaikan-Nya untuk dapat menyelesaikan masa perkuliahan di Sistem Informasi ITS dan telah memberikan kemudahan, kelancaran, serta kesehatan selama pengerjaan tugas akhir ini.
2. Ibu Badriyah dan Bapak Muslimin selaku kedua orang tua, yang selalu memberikan dukungan dalam berbagai bentuk, serta segenap keluarga penulis yang selalu memberikan motivasi.
3. Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen pembimbing dengan penuh keikhlasan dan dedikasi telah membimbing penulis dalam mengerjakan tugas akhir ini hingga selesai. Terima kasih atas kesediaan waktu, dan ilmu yang telah diberikan.
4. Bapak Edwin Riksakomara, S.Kom, M.T dan Bapak Faizal Mahananto, S.Kom., M.Eng., Ph.D. selaku penguji yang telah memberikan saran dan pengarahan untuk menyempurnakan tugas akhir ini. Terimakasih atas kesediaan waktu dan ilmu yang telah diberikan
5. Bapak Rully Agus Hendrawan, S.Kom, M.Eng. selaku dosen wali penulis yang selalu memberikan motivasi, nasihat, dukungan, dan saran selama penulis menempuh pendidikan SI.

6. Teman-teman OSIRIS dan semua pihak yang selalu mendukung dan memberi semangat dalam pengerjaan Tugas Akhir
7. Mas Ricky Asrul Sani selaku admin laboratorium Rekayasa Data dan Intelegensi Bisnis yang telah membantu dalam hal administrasi penyelesaian Tugas Akhir.
8. Seluruh dosen pengajar, staff, dan karyawan di Departemen Sistem Informasi FTIK ITS Surabaya yang telah memberikan ilmu dan bantuan kepada penulis selama ini.
9. Serta semua pihak yang telah membantu dalam pengerjaan Tugas Akhir ini yang belum mampu penulis sebutkan diatas.

Terima kasih atas segala bantuan, dukungan, serta doa yang diberikan. Semoga Tuhan yang Maha Esa senantiasa memberikan kesehatan, keselamatan, karunia dan nikmat-Nya. Penulis ingin memohon maaf apabila Tugas Akhir ini masih belum sempurna dengan segala kekurangan di dalamnya.

Surabaya, 3 Januari 2019



## DAFTAR ISI

ABSTRAK.....	v
ABSTRACT.....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xv
DAFTAR GAMBAR .....	xvii
DAFTAR KODE PROGRAM .....	xix
BAB I PENDAHULUAN .....	1
1.1. Latar belakang.....	1
1.2. Rumusan permasalahan.....	3
1.3. Batasan permasalahan .....	3
1.4. Tujuan.....	4
1.5. Manfaat .....	4
1.6. Relevansi .....	5
1.7. Sistematika penulisan.....	5
BAB II TINJAUAN PUSTAKA .....	7
2.1. Studi sebelumnya.....	7
2.2. Dasar teori.....	10
2.2.1 Demam Berdarah Dengue .....	10
2.2.2 Teknik Peramalan.....	11
2.2.3 Regresi .....	11
2.2.4 Suport Vektor Regresi .....	12
2.2.5 Evaluasi Hasil Peramalan .....	15
BAB III METODE Pengerjaan Tugas Akhir .....	17
3.1. Tahapan pelaksanaan tugas akhir .....	17
3.2. Uraian metodologi .....	18
3.2.1. Persiapan .....	18
3.2.2. Perancangan .....	19
3.2.3. Implementasi.....	20
3.2.4. Analisis Hasil Peramalan.....	21
3.2.5. Kesimpulan dan Saran.....	21
BAB IV PERANCANGAN .....	23
4.1. Persiapan Data .....	23

4.1.1. Pengumpulan Data .....	23
4.1.2. Pre-Processing Data .....	24
4.2 Pembuatan Suport Vektor Regresi .....	26
4.2.1 Gambaran Data Masukan .....	26
4.2.2 Pembagian Data Training dan Testing .....	29
4.2.3 Menentukan Parameter dan Kernel .....	30
4.3 Cross Validation .....	35
4.4 Peramalan Data .....	35
4.5 Analisa Hasil Peramalan .....	35
4.6 Gambaran Data Keluaran .....	35
<b>BAB V IMPLEMENTASI .....</b>	<b>37</b>
5.1 Pembagian data Training dan Testing .....	37
5.2 Optimasi Hyperparameter .....	38
5.3 Cross Validation .....	40
5.4 Peramalan Data .....	44
5.4.1 Peramalan Data Training .....	45
5.4.2 Peramalan Data Testing .....	46
5.4.3 Peramalan 1 Tahun kedepan .....	47
<b>BAB VI HASIL DAN PEMBAHASAN .....</b>	<b>49</b>
6.1 Hasil Grid Search .....	49
6.1.1 Dataran Tinggi .....	49
6.1.2 Dataran Sedang .....	51
6.1.3 Dataran Rendah .....	53
6.2 Hasil Cross Validation .....	54
6.2.1 Dataran Tinggi .....	55
6.2.2 Dataran Sedang .....	57
6.2.3 Dataran Rendah .....	59
6.3 Hasil Uji Coba Model .....	60
6.4 Validasi Model .....	61
6.5 Parameter yang digunakan untuk Peramalan .....	62
6.6 Hasil Peramalan dan Analisa .....	62
6.6.1 Dataran Tinggi .....	63
6.6.2 Dataran Sedang .....	65
6.6.3 Dataran Rendah .....	67
6.7 Kesimpulan Hasil Peramalan .....	68
<b>BAB VII KESIMPULAN DAN SARAN .....</b>	<b>69</b>
7.1 Kesimpulan .....	69

7.2 Saran.....	69
DAFTAR PUSTAKA .....	71
BIODATA PENULIS .....	75
Lampiran A .....	A-1
Lampiran B .....	A-5
Lampiran C .....	A-11
Lampiran D .....	A-26
Lampiran E.....	A-31

*Halaman sengaja dikosongkan*

## DAFTAR TABEL

Tabel 2.1 Kategori MAPE.....	15
Tabel 4.1 terdapat <i>Missing Data</i> .....	24
Tabel 4.2 Data Curah Hujan Periode Harian .....	25
Tabel 4.3 Mengubah Data Harian Ke Mingguan.....	26
Tabel 4.4 Data Training .....	29
Tabel 4.5 Data Testing .....	29
Tabel 4.6 Fungsi Kernel .....	31
Tabel 5.1 Logical Index Data Training.....	37
Tabel 5.2 Index Testing.....	38
Tabel 5.3 Hasil Optimasi Hyperparameter .....	40
Tabel 5.4 Input Cross Validation.....	41
Tabel 5.5 Output Cross Validation.....	44
Tabel 6.1 Parameter Terbaik untuk setiap kernel di desa Tambakrejo .....	50
Tabel 6.2 Parameter Terbaik untuk setiap kernel di desa Sitarjo .....	51
Tabel 6.3 Parameter Terbaik untuk setiap kernel di desa Dalisodo .....	52
Tabel 6.4 Parameter Terbaik untuk setiap kernel di desa Sumbermanjing Wetan.....	53
Tabel 6.5 Parameter Terbaik untuk setiap kernel di desa Pandansari .....	54
Tabel 6.6 Hasil Uji Coba Model.....	60

*Halaman sengaja dikosongkan*

## DAFTAR GAMBAR

Gambar 2.2 Fungsi Kernel Merubah Non-Linier Menjadi Linier .....	13
Gambar 2.3 k-fold = 3 fold cross validation. ....	14
Gambar 2.1 Loss Function E-sensitive model .....	16
Gambar 3.1 Metodologi Penelitian.....	18
Gambar 4.1 Grafik Data Jumlah Kasus DBD .....	27
Gambar 4.2 Grafik Data Suhu .....	27
Gambar 4.3 Grafik Data Kelembapan .....	28
Gambar 4.4 Grafik Data Curah Hujan .....	28
Gambar 4.5 Linear Kernel.....	31
Gambar 4.6 Gaussian Kernel.....	32
Gambar 4.7 Ploynomial kernel .....	32
Gambar 4.8 Perbedaan pola untuk Skala Kernel .....	33
Gambar 4.9 Polynomial Order 4 .....	34
Gambar 4.10 Polynomial Order 5 .....	34
Gambar 6.1 Perbandingan Parameter pada setiap jenis kernel di Tambakrejo .....	55
Gambar 6.2 Perbandingan Parameter pada setiap jenis kernel di Sitiarjo.....	56
Gambar 6.3 Perbandingan Parameter pada setiap jenis kernel di Sitiarjo.....	57
Gambar 6.4 Perbandingan Parameter pada setiap jenis kernel di Sumbermanjing Wetan .....	58
Gambar 6.5 Perbandingan Parameter pada setiap jenis kernel di Pandansari .....	59
Gambar 6.6 Hasil Peramalan Tambakrejo .....	63
Gambar 6.7 Hasil Peramalan Desa Sitiarjo .....	64
Gambar 6.8 Peramalan di Desa Dalisodo .....	65
Gambar 6.9 Peramalan Data di Desa Sumbermanjing Wetan ....	66
Gambar 6.10 Peramalan di Desa Pandansari .....	67

*Halaman sengaja dikosongkan*



## DAFTAR KODE PROGRAM

Kode Program 5.1 Optimasi Hyperparameter .....	39
Kode Program 5.2 Input Cross Validation .....	42
Kode Program 5.3 Proses dan Menyimpan Hasil Cross Validation.....	43
Kode Program 5.4 Peramalan kernel Gaussian pada data training .....	45
Kode Program 5.5 Peramalan menggunakan Kernel Gaussian pada data Testing .....	46
Kode Program 5.6 Peramalan 1 tahun kedepan menggunakan Kernel Polynomial di desa Sitiarjo .....	47

*Halaman sengaja dikosongkan*

# **BAB I**

## **PENDAHULUAN**

Bab ini menjelaskan mengenai latar belakang dilakukannya penelitian, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, relevansi tugas akhir, dan sistematika penulisan.

### **1.1. Latar belakang**

Demam berdarah dengue (DBD) adalah suatu penyakit yang disebabkan oleh infeksi virus dengue. DBD adalah penyakit akut dengan manifestasi klinis perdarahan yang menimbulkan syok yang berujung kematian. DBD disebabkan oleh salah satu dari empat serotipe virus dari genus *Flavivirus*, famili *Flaviviridae*. Setiap serotipe cukup berbeda sehingga tidak ada proteksisilang dan wabah yang disebabkan beberapa serotipe (hiperendemisitas) dapat terjadi. Virus ini bisa masuk ke dalam tubuh manusia dengan perantara nyamuk *Aedes aegypti* dan *Aedes albopictus*. Kedua jenis nyamuk ini terdapat hampir di seluruh pelosok Indonesia, kecuali di tempat-tempat ketinggian lebih dari 1000 meter di atas permukaan laut. Seluruh wilayah di Indonesia mempunyai resiko untuk terjangkit penyakit demam berdarah dengue, sebab baik virus penyebab maupun nyamuk penularnya sudah tersebar luas di perumahan penduduk maupun di tempat-tempat umum diseluruh Indonesia [1]. Penyebaran penyakit demam berdarah ini juga bergantung pada iklim ( suhu, kelembapan, curah hujan) [2], dan kepadatan penduduk [3].

Pada Tahun 2016, Kabupaten Malang termasuk dalam 3 besar kabupaten dengan jumlah kasus Demam Berdarah Tertinggi di Jawa Timur [4]. Bahkan, berdasarkan hasil kajian Badan Perencanaan, Penelitian, dan Pengembangan (Barenlitbang) Kota Malang, ada tren peningkatan penderita DBD sejak 2012–2016 [5]. Dinas Kesehatan Jatim terus berupaya

menyosialisasikan pencegahan DBD, seperti gerakan Satu Rumah Satu Jumantik (Juru Pemantau Jentik), mentoring klinik dan penyelenggaraan Bimtek Penyelidikan Epidemiologi, dan mendistribusikan dan menyiapkan stok logistik (insektisida, larvasida), serta peralatan berupa fogging serta Alat Pelindung Diri bagi fogger [4]. Selain itu perlu adanya cara untuk mendeteksi kemungkinan jumlah kasus demam berdarah demam berdarah di masa mendatang.

Peningkatan jumlah kasus demam berdarah dapat dideteksi dengan membuat suatu model peramalan yang dapat digunakan untuk pengambilan keputusan dalam menentukan penanganan kasus demam berdarah. Data hasil peramalan bisa digunakan untuk perencanaan pelayanan medis, seperti penanganan tepat waktu terhadap pasien dan ketersediaan obat-obatan yang dibutuhkan di masa yang akan datang.

Peramalan Penyakit demam berdarah pernah dilakukan sebelumnya di Indonesia, Malaysia dan Singapura. Di Indonesia penelitian demam berdarah dilakukan oleh Abdholatul Abdillah menggunakan metode Fuzzy, hasil dari penelitian ini memiliki nilai akurasi yang sangat rendah yaitu kurang dari 25% dan MSE 0,4 dari puluhan kasus [6], sedangkan penelitian demam berdarah di Malaysia menggunakan metode Support Vector Machine memiliki akurasi yang cukup tinggi yaitu 86% dan MSE 0,003 dari puluhan kasus [7]. Akan tetapi hasil terbaik adalah penelitian yang dilakukan di Singapura menggunakan metode Support Vector Regresi dengan nilai MSE 0,009 dari ratusan kasus [8]. Peramalan menggunakan metode Support Vector Regresi (SVR) memiliki nilai error terendah karena metode ini juga mempertimbangkan iklim yaitu suhu, curah hujan dan kelembapan sedangkan metode Fuzzy dan Support Vector Machine tidak mempertimbangkan perubahan iklim, oleh karena itu penelitian ini akan menggunakan metode Support Vector Regresi (SVR)

Support Vector Regression (SVR) merupakan versi regresi dari Support Vector Machine (SVM) yang diperkenalkan oleh Vapnik, Steven Golowich dan Alex Smola pada tahun 1997. Dasar pemikiran dari SVR adalah untuk memetakan set data ke ruang fitur dimensi tinggi non-linear dan menyelesaikan permasalahan regresi dalam ruang fitur dimensi ini [9]. Berdasarkan keunggulan dalam kapasitas menangani high dimensional data, SVR menjadi algoritma yang populer dalam memecahkan masalah peramalan [10].

Hasil dari peramalan yang di lakukan diharapkan bisa membantu Dinas Kesehatan Kabupaten Malang dalam menangani kasus demam berdarah di masa mendatang seperti persiapan obat – obatan, pelayanan pasien agar dapat mengurangi korban jiwa yang disebabkan oleh wabah ini..

## **1.2 Rumusan permasalahan**

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah pada penelitian ini adalah :

1. Bagaimana model terbaik akan digunakan dalam meramalkan jumlah kasus demam berdarah di beberapa desa di kabupaten malang?
2. Bagaimana hasil peramalan dengan menggunakan metode SVR?
3. Bagaimana hasil akurasi hasil peramalan jumlah kasus demam berdarah dengan metode SVR?

## **1.3 Batasan permasalahan**

Berdasarkan rumusan masalah diatas, batasan masalah dari tugas akhir ini adalah :

1. Peramalan ini hanya diterapkan pada kasus demam berdarah di kabupaten Malang
2. Data yang digunakan adalah data pasien per pekan untuk 5 desa didapatkan dari Dinas Kesehatan Kabupaten Malang pada tahun 2016-2017 sedangkan data suhu, curah hujan, kelembapan didapatkan dari BMKG

3. Data akan dikelompokkan menjadi 3 kelompok berdasarkan letak geografis desa, diantaranya yaitu: Dataran rendah, dataran sedang, dan dataran tinggi.
4. Pemilihan 5 desa diambil dengan proporsi 2 desa dari dataran rendah, 2 desa dari dataran sedang dan 1 desa dari dataran tinggi. Pada dataran tinggi diambil 1 desa karena hanya 1 desa yang memiliki data yang layak untuk diramalkan
5. Tools yang digunakan adalah Aplikasi Matlab R2018b berlisensi ITS

#### **1.4 Tujuan**

Berdasarkan rumusan masalah di atas, maka tugas akhir ini memiliki tujuan sebagai berikut :

- 1 Menemukan model SVR yang tepat untuk meramalkan jumlah kasus demam berdarah di kabupaten Malang.
- 2 Mengetahui hasil dan tingkat akurasi dalam peramalan data menggunakan metode SVR.

#### **1.5 Manfaat**

Dengan adanya penelitian ini diharapkan akan diperoleh manfaat sebagai berikut :

1. Bagi akademis  
Memperdalam ilmu pengetahuan serta dapat mempraktikkan atau mengimplementasikan dan mengembangkan ilmu pengetahuan yang diperoleh selama perkuliahan pada studi kasus yang nyata
2. Bagi Instansi  
Membantu Dinas Kesehatan Kabupaten Malang dalam mengatasi wabah demam berdarah berdasarkan hasil peramalan agar dapat melakukan persiapan untuk tindakan pencegahan dan perawatan pasien demam berdarah di masa yang akan datang
3. Bagi Masyarakat  
Menambah sumber pengetahuan dan pembelajaran bagi masyarakat mengenai peramalan jumlah kasus penderita demam berdarah menggunakan metode

SVR. Pembelajaran tersebut dapat diterapkan dalam penyelesaian suatu permasalahan yang serupa dan dapat dijadikan acuan untuk mengembangkan penelitian selanjutnya

## **1.6 Relevansi**

Tugas akhir ini berkaitan dengan Laboratorium Rekayasa Data dan Intelegensi Bisnis (RDIB) dengan topik peramalan, selain itu berkaitan dengan beberapa mata kuliah diantaranya Statistika, Teknik Peramalan, Sistem Pendukung Keputusan dan Tata Tulis Ilmiah.

Saat ini penelitian dengan topik peramalan sangat dibutuhkan semua organisasi termasuk organisasi yang bergerak dibidang kesehatan, karena dengan peramalan yang akurat dapat menyelamatkan lebih banyak pasien dan dapat menghemat anggaran untuk obat.

Karena wabah demam berdarah menyebar melalui vektor (vector borne disease) dimana akan meningkat berdasarkan iklim maka Metode SVR dapat dibilang sangat cocok untuk melakukan peramalan jumlah pasien demam berdarah, karena metode ini juga mempertimbangkan variabel lain seperti iklim.

## **1.7 Sistematika penulisan**

Dalam penulisan pada laporan hasil penelitian tugas akhir ini, terdapat sistematika penulisan yang diterapkan, antara lain terdiri dari beberapa bab berikut dibawah ini yang masing-masing memberikan informasi yang berbeda.

Adapun sistematika penulisan Laporan Tugas Akhir ini adalah sebagai berikut:

### **a. Bab I Pendahuluan**

Pada bab ini akan dijelaskan mengenai latar belakang permasalahan, rumusan masalah yang timbul, batasan, tujuan, dan manfaat pengerjaan tugas akhir.

### **b. Bab II Tinjauan Pustaka dan Dasar Teori**

Pada bab ini akan dijelaskan mengenai penelitian-penelitian sebelumnya yang berkaitan dengan tugas akhir, serta dasar teori yang digunakan pada penelitian akhir ini.

**c. Bab III Metodologi**

Pada bab ini akan dijelaskan mengenai tahapan-tahapan dalam melakukan penelitian, bahan dan alat yang harus dipersiapkan, serta jadwal kegiatan.

**d. Bab IV Perancangan**

Pada bab ini akan dijelaskan mengenai rancangan yang akan digunakan untuk implementasi metode yang digunakan.

**e. Bab V Implementasi**

Pada bab ini akan dijelaskan mengenai hasil implementasi yang sudah dilakukan selama penelitian.

**f. Bab VI Analisis Hasil dan Pembahasan**

Pada bab ini akan dijelaskan mengenai analisis dan pembahasan dalam penyelesaian permasalahan yang dibahas pada pengerjaan tugas akhir.

**g. Bab VII Kesimpulan dan Saran**

Pada bab ini akan dijelaskan mengenai kesimpulan dari hasil implementasi yang telah dilakukan dan saran yang ditujukan untuk kelengkapan penyempurnaan tugas akhir ini.



## **BAB II**

### **TINJAUAN PUSTAKA**

Bab ini berisi mengenai studi sebelumnya yang berhubungan dengan tugas akhir dan teori - teori yang berkaitan dengan permasalahan tugas akhir.

#### **2.1 Studi sebelumnya**

Dalam pengerjaan tugas akhir ini, perlu adanya pedoman dan referensi dari penelitian terdahulu untuk mendapatkan dasar teori dan masukan sebagai bahan dasar yang akan dipakai.. Tabel 2.1 merupakan penjelasan mengenai deskripsi, metode, hasil serta keterkaitan dari penelitian terdahulu dengan tugas akhir ini:

**Tabel 2. 1 Penelitian Sebelumnya**

Penelitian 1 [6]	
Judul Penelitian	<i>Peramalan Jumlah Kasus Demam Berdarah Di Beberapa Desa Kabupaten Malang Menggunakan Metode Fuzzy Inference System</i>
Penulis	Abdholatul Abdillah
Tahun Penelitian	2018
Gambaran Umum	Penelitian ini menghasilkan model peramalan dengan metode Fuzzy Inference System tanpa mempertimbangkan variable lain. penelitian ini mengelompokkan data kecamatan menjadi tiga berdasarkan letak geografis yaitu dataran rendah, dataran sedang, dataran tinggi. Penelitian ini hanya menggunakan data dari beberapa desa di kecamatan Hasil peramalan untuk jumlah kasus demam berdarah di lima desa pada tiap dataran menunjukkan akurasi yang kurang baik (buruk) karena semua

	desa memiliki nilai SMAPE yang besar diatas 50%. Sedangkan untuk nilai MAD dan MSE tergolong kecil. Nilai error yang cukup besar kemungkinan disebabkan oleh faktor metode atau parameter yang kurang tepat diterapkan dalam data jumlah kasus demam berdarah ini
Keterkaitan	Penelitian ini menjadi acuan utama dalam penelitian tugas akhir ini karena studi kasus yang di gunakan adalah sama. Karena hasil penelitian ini memiliki error yang cukup tinggi maka tugas akhir ini akan menggunakan metode lain yaitu SVR yang diharapkan akan memperkecil nilai error
Penelitian 2 [3]	
Judul Penelitian	<i>Forecasting The Number of Dengue Fever Cases in Malang Regency Indonesia Using Fuzzy Inference System Models</i>
Penulis	Wiwik Anggraeni, I Putu Agus Aditya Pramana, Febriliyan Samopa
Tahun Penelitian	2016
Gambaran Umum	Penelitian ini menghasilkan model peramalan dengan metode Fuzzy Inference System dengan menggunakan variabel kepadatan penduduk, penelitian ini mengelompokkan data kecamatan menjadi tiga berdasarkan letak geografis yaitu dataran rendah, dataran sedang, dataran tinggi. Hasil peramalan menunjukkan bahwa variable kepadatan penduduk sangat berpengaruh

	terhadap hasil peramalan
Keterkaitan	Penelitian ini digunakan untuk referensi awal dalam meramalkan kasus demam berdarah dengan menggunakan metode yang mempertimbangkan variabel lain.
Penelitian 3 [11]	
Judul Penelitian	<i>Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings</i>
Penulis	Yongbao Chen, Peng Xu, Yiyi Chu, Weilin Li, Yuntao Wu, Lizhou Ni, Yi Bao, Kun Wang
Tahun Penelitian	2017
Gambaran Umum	Penelitian ini meramalkan beban listrik menggunakan variabel lain yaitu waktu bekerja, dan cuaca. Data yang digunakan adalah data beban listrik pada 4 kantor. Setelah menganalisa hasil prediksi model, peneliti menemukan bahwa model SVR memberikan tingkat akurasi prediksi dan stabilitas yang lebih tinggi dalam perkiraan beban listrik jangka pendek dibandingkan dengan tujuh model peramalan tradisional lainnya.
Keterkaitan	Penelitian ini menggunakan tipe data yang sama yaitu konstan kemudian terdapat fluktuasi yang tiba – tiba tinggi. Penelitian ini juga memiliki metode yang sama dengan tugas akhir ini yaitu SVR.

## **2.2 Dasar teori**

Pada bagian ini berisi penjelasan mengenai dasar teori dan studi literatur yang dipakai selama penelitian untuk mengerjakan tugas akhir ini. Berikut adalah dasar teori dan studi literatur yang digunakan :

### **2.2.1 Demam Berdarah Dengue**

Demam berdarah dengue (DBD) adalah suatu penyakit yang disebabkan oleh infeksi virus dengue. DBD adalah penyakit akut dengan manifestasi klinis perdarahan yang menimbulkan syok yang berujung kematian. DBD disebabkan oleh salah satu dari empat serotipe virus dari genus *Flavivirus*, famili *Flaviviridae*. Setiap serotipe cukup berbeda sehingga tidak ada proteksisilang dan wabah yang disebabkan beberapa serotipe (hiperendemisitas) dapat terjadi. Virus ini bisa masuk ke dalam tubuh manusia dengan perantara nyamuk *Aedes aegypti* dan *Aedes albopictus*. Kedua jenis nyamuk ini terdapat hampir di seluruh pelosok Indonesia, kecuali di tempat-tempat ketinggian lebih dari 1000 meter di atas permukaan laut. Seluruh wilayah di Indonesia mempunyai resiko untuk terjangkit penyakit demam berdarah dengue, sebab baik virus penyebab maupun nyamuk penularnya sudah tersebar luas di perumahan penduduk maupun di tempat-tempat umum diseluruh Indonesia. [1]

Peningkatan jumlah kasus demam berdarah dapat dideteksi dengan membuat suatu model peramalan yang dapat digunakan untuk pengambilan keputusan dalam menentukan penanganan kasus demam berdarah, data hasil peramalan bisa digunakan perencanaan pelayanan medis, seperti penanganan tepat waktu terhadap pasien dan ketersediaan obat-obatan yang dibutuhkan di masa yang akan datang

### **2.2.2 Teknik Peramalan**

Peramalan adalah memprediksi apa yang akan terjadi di masa depan untuk menghindari kerugian. Risiko untuk prediksi yang buruk adalah kemungkinan kehilangan kontrol dalam proses produksi, atau keuntungan dalam bisnis [12]. ada beberapa tahapan peramalan diantaranya : Identifikasi Masalah, Memilih periode untuk forecaast, Memilih model yang akan digunakan, mengumpulkan data, menerapkan model pada data yang digunakan kemudian mengevaluasi hasil [13].

Peramalan berdasarkan sifatnya dapat dibedakan menjadi dua yaitu [14]:

1. Metode Kualitatif

Peramalan yang didasarkan pada data kualitatif masa lalu yang digabungkan dengan pemikiran dari penyusunnya.

2. Metode Kuantitatif

Peramalan yang didasarkan pada data kuantitatif dari data sebelumnya dan variabel sebab akibat. Hasil peramalan bergantung pada metode yang akan digunakan, karena setiap metode memiliki hasil peramalan yang berbeda pula. Peramalan secara kuantitatif ini dibagi lagi menjadi dua, yaitu model deret waktu (time series) dan model kasual.

### **2.2.3 Regresi**

Istilah regresi (ramalan/taksiran) pertama kali diperkenalkan oleh Sir Francis Galton pada tahun 1877 sehubungan dengan penelitiannya terhadap tinggi manusia, yaitu antara tinggi anak dan tinggi orang tuanya. Pada penelitiannya Galton mendapatkan bahwa tinggi anak dari orang tua yang tinggi cenderung meningkat atau menurun dari berat rata-rata populasi. Garis yang menunjukkan hubungan tersebut disebut garis regresi [15]. Pada metode regresi umumnya variabel yang diramalkan dinyatakan sebagai variabel yang dicari (dependent variable), variabel ini dipengaruhi besarnya oleh variabel bebas (independent variable).

Metode prediksi regresi dibedakan menjadi dua yaitu regresi linier, dan regresi non linier [16]:

### 1. Regresi non-Linier

Regresi non linier ialah bentuk hubungan di mana variabel bebas  $X$  dan atau variabel tak bebas  $Y$  dapat berfungsi sebagai faktor atau variabel bersifat kuadratik dan kubik dengan kurva yang dihasilkan membentuk garis lengkung selain itu, regresi non linear juga mempunyai banyak kurva yang bisa di bentuk [17].

### 2. Regresi Linier

Pola yang ditunjukkan dengan analisa regresi yang sederhana mengasumsikan bahwa hubungan diantara 2 variabel dapat dinyatakan dengan suatu garis lurus [18]. Notasi regresi sederhana yang merupakan pola garis lurus dinyatakan sebagai berikut [16].

$$Y = a + bX$$

Dimana  $Y$  adalah variabel yang diramalkan,  $x$  adalah variabel waktu, serta  $a$  dan  $b$  adalah parameter atau koefisien regresi. Untuk mencari garis lurus tersebut, kita perlu mencari besaran  $a$  dan  $b$ , besaran tersebut merupakan nilai konstan yang tidak akan berubah di dalam penganalisaan yang dilakukan.

Untuk mendapatkan nilai  $a$  dan  $b$  maka bisa didapatkan dari rumus berikut [16]:

$$a = \frac{\sum y - b \sum x}{n}$$

$$b = \frac{n \sum XY - (\sum X)(\sum Y)}{n \sum X^2 - (\sum X)^2}$$

## 2.2.4 Suport Vektor Regresi

Support Vector Regression (SVR) merupakan versi regresi dari Support Vector Machine (SVM) yang diperkenalkan oleh Vapnik, Steven Golowich dan Alex Smola pada tahun 1997. Dasar pemikiran dari SVR adalah untuk memetakan set data ke ruang fitur dimensi tinggi non-linear dan menyelesaikan permasalahan regresi dalam ruang fitur dimensi ini [9].

Peratama – tama kita akan membahas tentang model SVR, kemudian

kernel dan terakhir adalah Cross validation

### 2.2.4.2 Model SVR

Model SVR ini sama dengan rumus regresi linier karena regresi linier merupakan basis utama dari SVR [19].

$$f(x) = \omega^T x + b$$

Dimana parameter  $\omega$  dan  $b$  tidak diketahui. dengan meminimalkan risiko menggunakan prinsip SRM, maka bentuk standar linier SVR adalah [20] :

$$\min_{\omega, b, \xi, \xi^*} \frac{1}{2} \omega^T \omega + C \sum_{i=1}^l \xi_i + C \sum_{i=1}^l \xi_i^*$$

subject to

$$y_i - \omega^T x_i - b \leq \varepsilon + \xi_i$$

$$\omega^T x_i + b - y_i \leq \varepsilon + \xi_i^*$$


$$\xi_i, \xi_i^* \geq 0, i = 1, \dots, l.$$

C adalah nilai pre-specific yang di tentukan antara  $f(x)$  dan  $\varepsilon$

### 2.2.4.3 Kernel

Fungsi kernel memungkinkan kita untuk mengimplementasikan suatu model pada ruang dimensi lebih tinggi (ruang fitur) tanpa harus mendefinisikan fungsi pemetaan dari ruang input ke ruang fitur. Sehingga, untuk kasus yang *nonlinear regresi* pada ruang input, diharapkan akan menjadi *linear regresi* pada ruang fitur. Selanjutnya, kita dapat menggunakan *hyperplane* sebagai decision boundary secara efisien.

Untuk lebih jelasnya lihat gambar 2.2 :



**Gambar 2.1 Fungsi Kernel Merubah Non-Linier Menjadi Linier**

Berikut adalah rumus – rumus kernel [21] :

- a. Polynomial Kernel Function

$$K(x, x') = (x \cdot x')^d$$


- b. Radial Basis Function

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2g^2}\right)$$

Rumus – rumus kernel diatas digunakan bergantung dengan kondisi input space, kita juga bisa menggunakan 2 kernel atau lebih secara bersamaan. Terdapat banyak rumus kernel tetapi yang sering digunakan adalah fungsi kernel Polynomial dan Radial Basis

#### 2.2.4.4 Cross Validation

Akurasi estimasi SVR tergantung pada pengaturan yang baik dari meta-parameter C dan parameter kernel. Implementasi perangkat lunak yang ada dari SVR biasanya memperlakukan meta-parameter SVR sebagai input yang ditetapkan pengguna dan parameter fungsi kernel biasanya berdasarkan pada pengetahuan domain-aplikasi. Perlu diketahui bahwa parameter berpengaruh sangat besar terhadap hasil peramalan. Cross Validation merupakan cara yang paling *reliable* untuk menentukan parameter khususnya pada jumlah data yang kecil atau sedang, cross validation membagi data menjadi dua yaitu data validasi dan data training. K-fold equally adalah bentuk utama dari cross validation, jadi data dibagi menjadi k bagian. Untuk lebih jelasnya perhatikan gambar 2.3.



**Gambar 2.2** Pada gambar ini k-fold = 3 fold cross validation. data dengan warna gelap digunakan sebagai data training sedangkan data yang berwarna cerah digunakan untuk data validasi



## 2.2.5 Evaluasi Hasil Peramalan

Untuk mengetahui keakuratan hasil peramalan dilakukan evaluasi dengan menggunakan metode perhitungan kesalahan dalam peramalan.

### 2.2.5.2 *Symmetric Mean Absolute Percentage Error*

Symmetric Mean Absolute Percentage Error (SMAPE) merupakan salah satu alternatif untuk Mean Absolute Percentage Error (MAPE) ketika terdapat angka nol atau mendekati nol di nilai aktual. Untuk range hasil analisis error berada diantara 0-100 % . Rumus SMAPE secara umum dapat dituliskan [22]:

$$SMAPE = \frac{100\%}{n} \sum_{t=1}^n \left( \frac{|F_t - A_t|}{|A_t| + |F_t|} \right)$$

Dengan :

SMAPE = Symmetric Mean Absolute Percentage Error

N = Jumlah Sampel

F<sub>t</sub> = Nilai prediksi indeks pada periode ke-t

A<sub>t</sub> = Nilai actual indeks pada periode ke-t

Tabel 2.1 merupakan perbandingan tingkat akurasi hasil peramalan SMAPE berdasarkan penyesuaian dari evaluasi hasil peramalan MAPE.

**Tabel 2.1 Kategori MAPE**

MAPE	Hasil Peramalan
≤ 10%	Sangat Bagus
11 - 20%	Baik
21 - 50%	Cukup
> 50%	Buruk

### 2.2.5.2 Mean Square Error

Mean Square Error (MSE) merupakan perhitungan yang menguadratkan masing masing sisa atau kesalahan. Rumus MSE secara umum dapat dituliskan [22]:

$$\text{MSE} = \sum_{t=1}^n \left( \frac{(At - Ft)^2}{n} \right)$$

Dengan :

MSE = Mean Square Error

n = Jumlah Sampel

Ft = Nilai prediksi indeks pada periode ke-t

At = Nilai actual indeks pada periode ke-t


### 2.2.5.3 Loss $\epsilon$ -insensitive

Fungsi loss untuk  $\epsilon$ -insensitive model adalah: loss = 0 jika jarak antara forecast dan data aktual kurang dari  $\epsilon$ (Epsilon), jika jarak lebih dari  $\epsilon$  maka  $\xi > 0$ .

Berikut adalah rumus loss function [20].

$$L(y, f(x, \alpha)) = |\xi|_{\epsilon} = \begin{cases} 0 & \text{if } |\xi| \leq \epsilon \\ |\xi| - \epsilon & \text{if } |\xi| > \epsilon, \end{cases}$$

Untuk lebih jelas tentang loss function lihat gambar 2.1 :



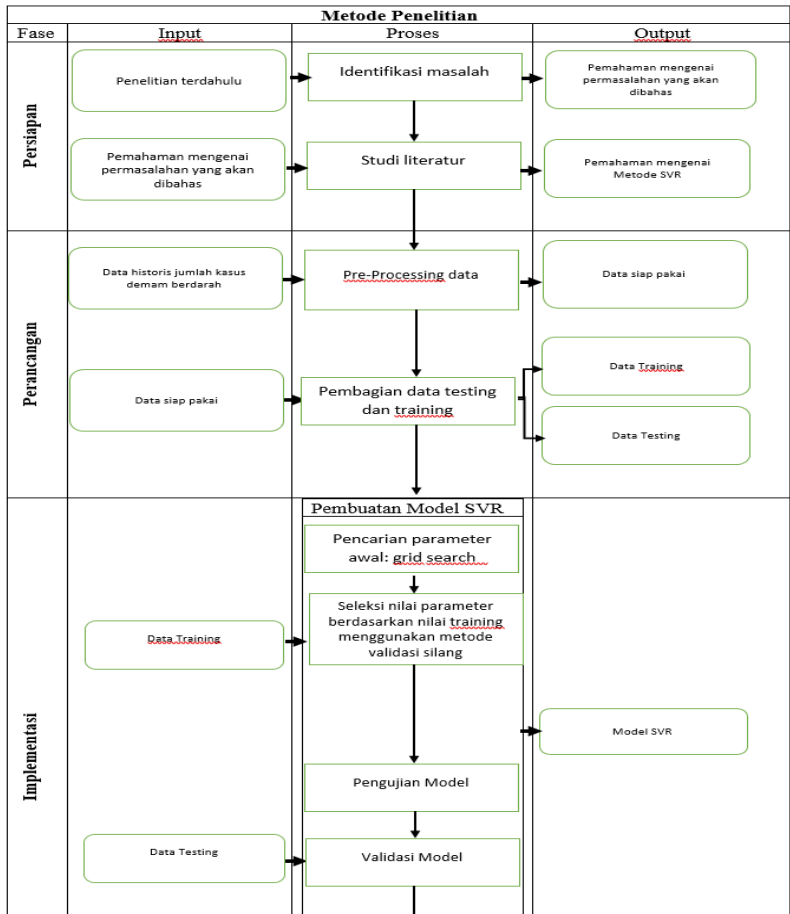
Gambar 2.3 Loss Function E-sensitive model

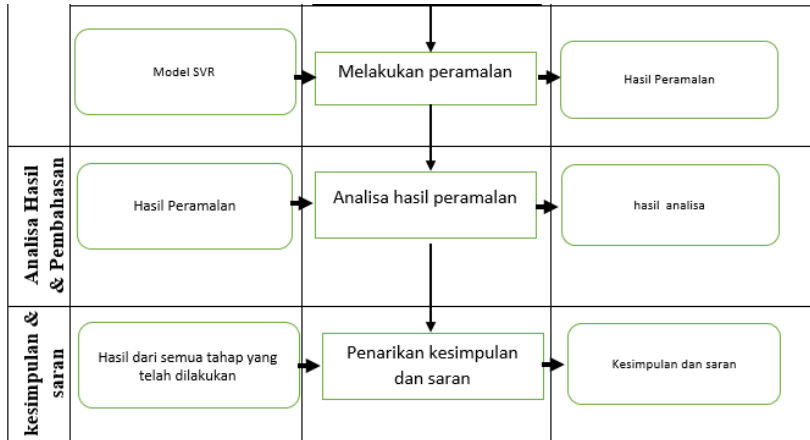
## BAB III METODE Pengerjaan Tugas Akhir

Bab ini berisi tentang metodologi pengerjaan yang akan dilakukan untuk menyelesaikan penelitian tugas akhir ini

### 3.1. Tahapan pelaksanaan tugas akhir

Gambar 3.1 merupakan tahapan dari metode pengerjaan tugas akhir ini





**Gambar 3.1 Metodologi Penelitian**

### 3.2. Uraian metodologi

Pada sub bab ini akan dijelaskan lebih detail setiap proses yang ada dalam metodologi pelaksanaan tugas akhir ini.

#### 3.2.1. Persiapan

Pada fase ini merupakan langkah awal dalam pengerjaan Tugas Akhir yang dilakukan adalah persiapan. Penulis melakukan persiapan dengan dua kegiatan yaitu identifikasi masalah dan studi literatur.

##### 3.2.1.1. Identifikasi Masalah

Kegiatan pertama pada fase persiapan yaitu melakukan identifikasi masalah. Pada kegiatan ini penulis berusaha mencari suatu masalah dari penelitian sebelumnya, pada kasus ini yaitu penelitian yang dilakukan oleh Abdholatul Abdullah. Pada penelitian tersebut penulis menemukan masalah bahwa hasil peramalan jumlah kasus DBD memiliki nilai error yang tinggi.

##### 3.2.1.2. Studi Literatur

Setelah melakukan identifikasi permasalahan, kemudian dilakukan studi literatur untuk menemukan solusi dari permasalahan yang muncul. Studi literatur bersumber dari

penelitian sebelumnya, buku, dan jurnal. Hasil dari kegiatan ini berupa pemahaman penulis bahwa kasus DBD akan meningkat berdasarkan iklim, sehingga diperlukan metode yang dapat memperhitungkan variable lain.

### **3.2.2. Perancangan**

Pada fase ini dilakukan proses perancangan mulai dari persiapan data, pengumpulan data, pre-processing data, pembagian data menjadi data testing dan training. Kegiatan ini fokus pada pengolahan data sehingga data nantinya akan siap digunakan untuk pembuatan model SVR. Berikut adalah tahapan dari kegiatan ini.

#### **3.2.2.1. Pengumpulan dan Pre-Processing Data**

Pada tahapan ini data yang dibutuhkan dalam pengerjaan tugas akhir ini akan dikumpulkan dan disiapkan untuk pengolahan. Data jumlah kasus demam berdarah didapat dari Dinas Kesehatan Kabupaten Malang dalam bentuk excel. Data dari Dinas Kesehatan Kabupaten Malang adalah data per pekan per desa pada tahun 2016-2017. Pemilihan 5 desa berdasarkan data yang paling layak diramalkan dan mewakili dari masing-masing dataran berdasarkan letak geografis desa. Penentuan letak geografis desa berdasarkan peta dataran Kabupaten Malang yang kemudian dilakukan klasifikasi berdasarkan warna-warna yang menunjukkan letak desa tersebut (Hijau menunjukkan dataran rendah dengan ketinggian 0 – 400 meter, Kuning tua menunjukkan dataran sedang dengan ketinggian 400 – 1000 meter, dan Kuning menunjukkan dataran tinggi dengan ketinggian > 1000 meter).

#### **3.2.2.2. Pembagian data training dan testing**

Pada tahap ini data akan dibagi menjadi data training dan data testing dengan proporsi data training 80% dan data testing 20%, kemudian data training dibagi menjadi 4 bagian (*fold*), pembagian data training ini digunakan untuk melakukan *cross validation* yang bertujuan untuk mencari model terbaik sedangkan data testing digunakan untuk validasi model.

### 3.2.3. Implementasi

Pada fase ini dilakukan pembuatan model dan melakukan peramalan. Pembuatan model dilakukan untuk mencari model (parameter) yang paling cocok untuk data yang digunakan agar hasil peramalan memiliki error yang kecil.

#### 3.2.3.1. Pembuatan Model SVR

Pembuatan model SVR memiliki 4 tahap yaitu penentuan parameter awal, seleksi nilai parameter, pengujian model, plot prediksi. Model SVR yang dihasilkan diperoleh setelah menjalankan skript berulang kali, dan didapatkan hasil yang stabil untuk berbagai percobaan menggunakan nilai interval parameter yang berbeda.

1. Pencarian Parameter awal (grid search)  
Algoritma pembelajaran supervisi SVR membutuhkan data training sampel. Oleh karena pada model SVR juga terdapat Parameter set up [23]. Proses pencarian parameter model dan set up parameter (hyperparameter) menggunakan metode grid search
2. Seleksi nilai parameter (cross validation)  
metode validasi silang k-lipatan untuk menghasilkan model terbaik dengan nilai parameter optimal, jumlah lipatan yang digunakan adalah 4. Proses seleksi model SVR dilakukan melalui beberapa eksperimen menggunakan fungsi kernel Radial Basis, linear dan polinom. [23]
3. Pengujian model  
Pada tahapan ini akan dilakukan uji model terhadap hasil yang telah didapat pada proses sebelumnya. Uji coba dilakukan pada seluruh train set, pada tahap seleksi nilai parameter data training yang digunakan dibagi menjadi 4-lipatan akan tetapi pada tahap ini data training sudah menjadi 1 kesatuan. Pada tahapan ini sudah ditentukan model yang digunakan untuk peramalan.

#### 4. Validasi Model

tahapan ini akan dilakukan validasi model yang telah dihasilkan pada tahapan sebelumnya. Validasi model menggunakan data test set. Hasil dari tahapan ini akan menunjukkan model yang bisa digunakan untuk meramalkan data yang berbeda.

##### **3.2.3.2. Peramalan**

Pada tahap akan dilakukan peramalan pada data training dan testing. Peramalan dilakukan dengan menggunakan model SVR terbaik, hasil peramalan ini nantinya akan dianalisa pada tahap berikutnya.

Hasil peramalan ini berupa nilai spesifik yang memiliki garis batas  $\epsilon$ , jika data aktual berada di dalam garis maka loss dianggap 0. [21]

##### **3.2.4. Analisis Hasil Peramalan**

Pada tahap ini akan dilakukan analisis terhadap hasil peramalan yang bertujuan untuk menguji tingkat keakuratan hasil peramalan dengan melihat nilai MAPE, MSE dan MAD. Jika nilai *error* dapat diterima, maka dapat dikatakan bahwa hasil peramalan dapat akurat. Selain itu pada tahapan ini dilakukan analisa mengenai peningkatan atau penurunan jumlah kasus demam berdarah

##### **3.2.5. Kesimpulan dan Saran**

Pada fase ini akan penarikan kesimpulan akhir dari serangkaian proses penelitian tugas akhir dengan studi peramalan kasus DBD di Kabupaten Malang. Selain itu terdapat saran yang diberikan untuk Dinas Kesehatan Kabupaten Malang

*Halaman ini sengaja dikosongkan*



## **BAB IV PERANCANGAN**

Pada bab ini akan dijelaskan mengenai perancangan yang akan dilakukan untuk mengerjakan tugas akhir mulai dari proses penggalian kebutuhan, pengumpulan data, persiapan data, serta pengolahan data yang merupakan pembuatan model dan proses peramalan yang dilakukan

### **4.1 Persiapan Data**

Pada tahap ini akan dilakukan proses pengumpulan data hingga data dapat digunakan dalam pengerjaan tugas akhir ini. Data yang digunakan pada tugas akhir ini adalah data jumlah kasus demam, data suhu, kelembapan dan curah hujan di Kabupaten Malang

#### **4.1.1. Pengumpulan Data**

Penelitian tugas akhir ini membutuhkan data jumlah kasus demam berdarah, suhu, kelembapan dan curah hujan.

Data jumlah kasus demam berdarah di Kabupaten Malang didapatkan dari Dinas Kesehatan Kabupaten Malang pada periode Januari 2016 hingga Desember 2017 dalam periode pekan. data tersebut merupakan data jumlah kasus demam berdarah dari 390 desa yang ada di Kabupaten Malang .

Dari 390 Desa yang ada di Kabupaten Malang akan dikelompokkan menjadi 3 berdasarkan letak geografisnya yaitu : Dataran Rendah, Dataran Sedang, Dataran Tinggi. Dari masing dataran tersebut diambil beberapa desa untuk digunakan dalam tugas akhir ini diantaranya : Dataran Rendah : Desa Sitiarjo, Desa Tambakrejo. Dataran Sedang : Desa Dalisodo, Desa Sumbermanjing Wetan dan Dataran Tinggi : Desa Pandansari

Penentuan letak geografis desa berdasarkan peta dataran Kabupaten Malang yang kemudian dilakukan klasifikasi berdasarkan warna-warna yang menunjukkan letak desa tersebut (Hijau menunjukkan dataran rendah dengan

ketinggian 0 – 400 meter, Kuning tua menunjukkan dataran sedang dengan ketinggian 400 – 1000 meter, dan Kuning menunjukkan dataran tinggi dengan ketinggian > 1000 meter). Pengelompokan data berdasarkan letak geografis dikarenakan pada letak dataran yang sama memiliki kesamaan pola data. Misalkan di dataran tinggi pola datanya tinggi pada minggu 1-33, berbeda dengan pola data di dataran sedang yang memiliki pola statis dengan nilai 0 pada minggu 1 – 33. Sedangkan data suhu, curah hujan dan kelembapan di Kabupaten Malang dari Januari 2016 hingga Desember 2017 dalam periode harian diambil dari BMKG Stasiun Klimatologi Malang

#### 4.1.2. Pre-Processing Data

Pada tahapan ini akan dilakukan pra-processing data dimulai dari melakukan perekapan data menjadi data per pekan dari yang sebelumnya berupa data harian. Tahap ini juga berfungsi untuk mengubah data mentah yang didapatkan menjadi data yang layak untuk digunakan penelitian. Pra-processing data pada penelitian juga melakukan penanganan terhadap *missing* data. *Missing* data pada penelitian ini terjadi karena data tidak ada atau data tidak terukur sehingga pada waktu tertentu data menjadi angka 9999 (tidak ada data) atau 8888 (data tidak terukur). Contoh *missing* data pada data iklim dapat dilihat pada tabel 4.1

**Tabel 4.1 terdapat Missing Data**

Tanggal	Curah Hujan
01/01/2016	11,8
02/01/2016	3,5
03/01/2016	22,8
04/01/2016	11,5
05/01/2016	0
06/01/2016	0
07/01/2016	0
08/01/2016	9999
09/01/2016	13
10/01/2016	13,4

Untuk mengatasi *missing data*, terdapat beberapa metode sederhana yang bisa dilakukan, antara lain :

1. Menghapus data  
Pada Metode ini jika ada kasus data yang hilang untuk salah satu variabel, maka cukup mengecualikan kasus itu dari analisis [24]. Metode menghapus data bisa digunakan ketika data yang dihapus tidak memengaruhi struktur *time series*. Pada penelitian ini metode penanganan *missing data* ini tidak dilakukan.
2. *Marginal mean imputation*  
Metode ini menghitung nilai rata – rata pada data yang telah ada dan diisikan ke data yang kosong [24]. Pada penelitian ini metode penanganan *missing data* ini tidak dilakukan.
3. *Last Observation Carried Foward (LOCF) dan Next Observation Carried Backward (NOCB)*  
Nilai non-missing yang diamati pada periode sebelumnya akan digunakan untuk mengisi data yang hilang pada periode ini (LOCF) [25]. Dan nilai non-missing pada next periode digunakan untuk mengisi data yang hilang pada periode ini (NOCB).

Setelah dilakukan proses penanganan data kosong, maka dihasilkan data pada tabel 4.2

**Tabel 4.2 Data Curah Hujan Periode Harian**

Tanggal	Curah Hujan
01/01/2016	11,8
02/01/2016	3,5
03/01/2016	22,8
04/01/2016	11,5
05/01/2016	0
06/01/2016	0
07/01/2016	0
08/01/2016	4,1
09/01/2016	13
10/01/2016	13,4

Setelah mengatasi *missing data* tahap selanjutnya dalam pre-processing data adalah mengubah data harian menjadi data

mingguan. Contoh pengubahan data harian ke data mingguan dapat dilihat dari tabel 4.3

**Tabel 4.3 Mengubah Data Harian Ke Mingguan**

Tanggal	Curah Hujan	Minggu ke	Curah Hujan (mingguan)
01/01/2016	11,8	1	7,085
02/01/2016	3,5		
03/01/2016	22,8		
04/01/2016	11,5		
05/01/2016	0		
06/01/2016	0		
07/01/2016	0		
08/01/2016	4,1	2	7,50
09/01/2016	13		
10/01/2016	13,4		
11/01/2016	20		
12/01/2016	2		
13/01/2016	0		
14/01/2016	0		


## **4.2 Pembuatan Suport Vektor Regresi**

Pada subbab ini dilakukan proses visualisasi data masukan yang akan proses menggunakan metode Suport Vektor Regresi dan tahapan-tahapan metode Suport Vektor Regresi sehingga mendapatkan model yang terbaik.

### **4.2.1 Gambaran Data Masukan**


Data masukan merupakan data yang didapatkan dari Dinas Kesehatan Kabupaten Malang yang sebelumnya dilakukan pengumpulan data. Data berformat excel berisi rekapan data jumlah kasus demam berdarah beserta dengan nama penderita, alamat desa penderita, tanggal diagnose, tanggal masuk rumah sakit, dll dari awal tahun 2016-2017. Data tersebut kemudian diolah menjadi data per pekan per desa untuk jumlah kasus demam berdarah dan didapatkan 104 pekan setelah dilakukan pra processing data Gambaran grafik dari data setelah

dilakukan pra-proses data dapat dilihat pada Gambar 4. 1 yang menunjukkan data jumlah kasus demam berdarah per pekan per dataran tinggi.




**Gambar 4.1 Grafik Data Jumlah Kasus DBD**

Gambaran grafik dari data Suhu setelah dilakukan pra-proses data dapat dilihat pada Gambar 4. 2




**Gambar 4.2 Grafik Data Suhu**

Gambaran grafik dari data Kelembapan setelah dilakukan pra-proses data dapat dilihat pada Gambar 4. 3



Gambar 4.3 Grafik Data Kelembaban

Gambaran grafik dari data Curah Hujan setelah dilakukan pra-proses data dapat dilihat pada Gambar 4. 4



Gambar 4.4 Grafik Data Curah Hujan

#### 4.2.2 Pembagian Data Training dan Testing

Pada tahapan ini dilakukan pembagian data pelatihan dan data pengujian dengan proporsi 80% untuk data pelatihan dan 20% untuk data pengujian. Sehingga, dari 104 data terbagi menjadi 84 data pelatihan dan 20 data pengujian. Berikut Data Pelatihan dapat dilihat pada tabel 4.4

**Tabel 4.4 Data Training**

No	Minggu	Sitiarjo	Suhu	Kelembapan	Curah Hujan
1	1	1	25.35714	78.57143	7.085714
2	2	3	25.52857	79.57143	7.5
3	3	0	25.3	78.85714	11.15714
4	4	0	24.37143	82.85714	4.3
5	5	0	24.68571	85	20.57143
6	6	1	23.71429	91.42857	21.38571
7	7	1	24.4	85.28571	10.82857
...	...	...	...	...	...
82	82	0	22.34286	78	5.457143
83	83	0	21.94286	81.14286	0.314286
84	84	0	22.98571	78.71429	0

Tabel 4.4 merupakan contoh sebagian data testing jumlah kasus demam berdarah di desa sitiarjo

**Tabel 4.5 Data Testing**

No	Minggu	Sitiarjo	Suhu	Kelembapan	Curah Hujan
1	85	0	22.32857	75.14286	0.057143
2	86	1	22.97143	74.85714	0
3	87	0	22.78571	72.71429	0
4	88	0	23.54286	73	0
5	89	0	23.67143	74.28571	0.057143
6	90	0	23.65714	69.28571	0.985714
7	91	1	24.44286	77.14286	6
...	...	...	...	...	...
18	102	0	24.14286	85.42857	9.371429
19	103	0	23.61429	87.57143	13.55714
20	104	0	24.18571	79.14286	2.157143

### 4.2.3 Menentukan Parameter dan Kernel

Dalam membuat model Suport Vektor Regresi perlu menentukan kernel apa yang paling cocok digunakan dan berapa skala dari kernel tersebut. Parameter epsilon, box constraint juga mempengaruhi hasil dari peramalan. Untuk menentukan parameter paling optimal perlu melakukan optimasi hyperparameter dengan menggunakan metode searching yaitu grid search.

#### 4.2.3.1 Grid Search

Grid Search merupakan cara tradisional melakukan optimasi hiperparameter yang hanya merupakan pencarian lengkap melalui subset spesifik dari ruang hyperparameter dari algoritma pembelajaran [26]. Berikut adalah contoh grid search :

$C = 10, 11, 12, 13, 14$

$D = 21, 22, 23$

Grid Search akan mencari parameter terbaik dari setiap pasangan (C,D) jadi grid search akan mencari (10,21) ; (10,22) sampai (14,23). Hasil Grid Search adalah parameter terbaik dari Box Constrain, Epsilon, Jenis Kernel, Kernel Scale, Polynomial Order (jika kernelnya polynomial)

#### 4.2.3.2 Box Constrain

Box constrain adalah parameter yang mengontrol pinalti maksimum yang dikenakan pada pengamatan yang melanggar margin, yang membantu mencegah overfitting (regularisasi).

Jika kita meningkatkan box constrain, maka classifier SVM menetapkan lebih sedikit suport vektor. Namun, meningkatkan box constrain dapat menyebabkan waktu pelatihan yang lebih lama



### 4.2.3.3 Epsilon

Fungsi loss untuk  $\varepsilon$ -insensitive model adalah:  $\text{loss} = 0$  jika jarak antara forecast dan data aktual kurang dari  $\varepsilon$  (Epsilon), jika jarak lebih dari  $\varepsilon$  maka  $\xi > 0$  [20]

### 4.2.3.4 Jenis Kernel

Beberapa masalah regresi tidak dapat dijelaskan secara memadai menggunakan model linier. Dalam kasus seperti itu, formulasi ganda Lagrange memungkinkan teknik Suport Vektor Regresi untuk diperluas ke fungsi nonlinier.


Dapatkan model regresi SVL nonlinier dengan mengganti produk titik  $x_1'x_2$  dengan fungsi kernel nonlinier  $G(x_1, x_2) = \langle \phi(x_1), \phi(x_2) \rangle$ , di mana  $\phi(x)$  adalah transformasi yang memetakan  $x$  ke ruang dimensi tinggi. Statistik dan Machine Learning Toolbox menyediakan fungsi-fungsi kernel semidefinite bawaan berikut.

**Tabel 4.6 Fungsi Kernel**

Nama Kernel	Rumus
Linear (dot product)	$G(x_j, x_k) = x_j'x_k$
Gaussian	$G(x_j, x_k) = \exp(-  x_j - x_k  ^2)$
Polynomial	$G(x_j, x_k) = (1 + x_j'x_k)^q$ , where $q$ is in the set $\{2, 3, \dots\}$ .


Berikut adalah gambar bentuk kernel jika di representasikan dalam bentuk grafik.

Gambar 4.5 merupakan gambar Linear kernel yang sama saja tanpa mendefinisikan kernel karena merupakan standar dalam linier regresi




**Gambar 4.5 Linear Kernel**

Gambar 4.6 merupakan gambar Gaussian Kernel yang mengubah pola non linier menjadi linier



**Gambar 4.6 Gaussian Kernel**


Gambar 4.7 merupakan gambar Ploynomial Kernel yang mengubah pola menjadi linier



**Gambar 4.7 Ploynomial kernel**

#### 4.2.3.5 Kernel Scale


Skala kernel mendeskripsikan seberapa mulus pola kernel tersebut. Jika nilai dari kernel scale kecil maka pola kernel lebih mudah berubah atau menjadi semakin kecil. Jika skala kernel besar maka perubahan pola akan semakin lambat. Gambar 4.8 menunjukkan perbedaan pola dalam nilai skala kernel.




Gambar 4.8 Perbedaan pola untuk Skala Kernel

#### 4.2.3.6 Polynomial Order

Derajat polinomial adalah derajat tertinggi monomialnya (istilah individual) dengan koefisien tidak nol. Istilah derajat adalah jumlah eksponen dari variabel yang muncul di dalamnya, dan dengan demikian adalah bilangan bulat non-negatif. Istilah Order telah digunakan sebagai sinonim dari derajat. Contohnya polynomial  $7x^3y^2 + 2x^4 + 12xy$  memiliki derajat masing masing 5, 4, 2 ( $3+2$ , 4,  $1+1$ ). Maka polynomial tersebut memiliki nilai Order = 5 karena 5 merupakan derajat tertinggi pada persamaan polynomial tersebut. Gambar 4.9 dan 4.10 merupakan contoh gambar polynomial kernel berdasarkan ordernya.



Gambar 4.9 Polynomial Order 4



Gambar 4.10 Polynomial Order 5

Dari kedua gambar 4.9 dan 4.10 dapat disimpulkan bahwa nilai polynomial order mempengaruhi pola naik turun pada fungsi kernel polynomial. Misalnya pada gambar 4.9 memiliki jumlah naik turun yaitu 4 dengan pola 2 turun dan 2 naik sehingga nilai polynomial ordernya adalah 4, begitu juga dengan gambar 4.10 yang memiliki jumlah naik turun sebanyak 5 dengan pola 2 turun dan 3 pola naik. sehingga dapat disimpulkan bahwa polynomial order sangat mempengaruhi struktur polynomial

### **4.3 Cross Validation**

Cross Validation berfungsi untuk melakukan pemilihan model dan mencari nilai error untuk setiap model [27] dan untuk menghindari overfitting [28]. 5 parameter terbaik untuk setiap kernel pada proses optimasi hyperparameter di setiap desa akan dilakukan validasi silang dengan output nilai loss e-insensitif.

### **4.4 Peramalan Data**

Setelah terbentuk model Suport Vektor Regresi terbaik maka langkah selanjutnya adalah dilakukan peramalan terhadap data jumlah kasus demam berdarah di Kabupaten Malang.

### **4.5 Analisa Hasil Peramalan**

Pada tahapan ini dilakukan analisa hasil peramalan yaitu dengan melihat tingkat keakuratan hasil peramalan yang dapat dilihat melalui SMAPE, MAD dan MSE. Dan juga melihat bagaimana kemampuan model peramalan dalam mengikuti pola dari data aktual

### **4.6 Gambaran Data Keluaran**

Data keluaran berupa hasil peramalan kasus demam berdarah di Kabupaten Malang dengan periode mingguan dari tahun 2016-2018 untuk Desa Sitiarjo dan Desa Tambakrejo di dataran rendah Desa Dalisodo dan Desa Sumbermanjing Wetan di dataran sedang dan Desa Pandansari di dataran tinggi.

*Halaman ini sengaja dikosongkan*

## **BAB V**

### **IMPLEMENTASI**

Pada bab ini akan dijelaskan mengenai pelaksanaan dari penelitian yang akan dilakukan yaitu dengan melakukan pembuatan model Suport Vektor Regresi yang selanjutnya digunakan untuk meramalkan data

#### **5.1 Pembagian data Training dan Testing**

Dalam pembuatan model peramalan, data akan dibagi menjadi dua yaitu train set dan test set dengan perbandingan 80:20. Data Train set akan membentuk model sedangkan data test set akan menunjukkan validitas dari model. pada model SVR diperlukan membuat logical indeks dengan angka 1 berarti diikuti sedangkan angka 0 berarti tidak diikuti. Tabel 5.1 merupakan tabel indeks training yang berisi angka 1 dari No. 1-84 dan angka 0 untuk No. 85-104

**Tabel 5.1 Logical Index Data Training**

No.	Logical Index
1	1
2	1
3	1
4	1
...	...
82	1
83	1
84	1
85	0
86	0
87	0
...	...
103	0
104	0

Tabel 5.2 merupakan tabel indeks testing yang berisi angka 0 dari No. 1-84 dan angka 1 untuk No. 85-104

**Tabel 5.2 Index Testing**

No.	Logical Index
1	0
2	0
3	0
4	0
...	...
82	0
83	0
84	0
85	1
86	1
87	1
...	...
103	1
104	1

## 5.2 Optimasi Hyperparameter

Parameter untuk dioptimalkan, ditentukan sebagai pasangan yang dipisahkan koma yang terdiri dari 'OptimizeHyperparameters' dan salah satu dari yang berikut:

- 'none' - tidak mengoptimalkan parameter apapun.
- 'auto' - mengoptimalkan {'BoxConstraint', 'KernelScale', 'Epsilon'}.
- 'all' - Optimalkan semua parameter yang memenuhi syarat.
- Array string atau array sel nama parameter yang memenuhi syarat.
- Vektor objek yang dapat dioptimalkan, biasanya output dari hyperparameter.



Parameter yang bisa dioptimalkan adalah :

- BoxConstraint - fitrsvm mencari di antara nilai-nilai positif, secara default log-scaled dalam kisaran  $[1e-3, 1e3]$ .
- KernelScale - fitrsvm mencari di antara nilai-nilai positif, secara default diskalakan dalam kisaran  $[1e-3, 1e3]$ .
- Epsilon - fitrsvm mencari di antara nilai-nilai positif, secara default log-scaled dalam kisaran  $[1e-3, 1e2] * \text{iqr}(Y) / 1.349$ .
- KernelFunction - fitrsvm mencari di antara 'gaussian', 'linear', dan 'polinomial'.
- PolynomialOrder - fitrsvm mencari di antara bilangan bulat dalam kisaran  $[2, 4]$ .
- Standarisasi - pencarian fitrsvm di antara 'true' dan 'false'.

Dapat dilihat pada Kode Program 5.1 bahwa kode pada baris 9 berguna untuk memilih parameter apa saja yang akan dioptimalkan, penelitian ini akan mengoptimalkan seluruh parameter yang dapat dioptimalkan yaitu BoxConstraint, KernelScale, Epsilon, Fungsi Kernel, Polynomial Order dan Standarisasi. Kode Pada baris 10 berguna untuk memilih metode optimasi. Penelitian ini menggunakan gridsearch sebagai metode optimasi, selain gridsearch terdapat 2 lagi metode optimasi yaitu random search dan bayes optimisation. Pada baris 12 menentukan iterasi maksimum yaitu 2000. Pada baris 13 berguna untuk menyimpan hasil optimasi dan kita dapat mengkategorikannya berdasarkan ranking error terkecil.

```

7
8 - mdlTrain = fitrsvm(tbl(idXTrn,:), 'DalisoDo', ...
9   'OptimizeHyperparameters', 'all', ...
10  'HyperparameterOptimizationOptions', struct('Optimizer', 'gridsearch', ...
11    'AcquisitionFunctionName', 'expected-improvement', ...
12    'MaxObjectiveEvaluations', 2000));
13 - HasilGridDalisoDo = sortrows(mdlTrain.HyperparameterOptimizationResults)
14

```

**Kode Program 5.1 Optimasi Hyperparameter**

Pada Tabel 5.3 terdapat nilai NaN pada PolynomialOrder jika kernel yang dipakai bukan Polynomial, sedangkan jika kernel yang dipakai adalah polynomial maka kernel scale yang bernilai NaN. Terdapat variable objective(error) yang berarti tujuan optimasi ini adalah mencari nilai objective terkecil dengan mengubah parameter - parameter yang dapat diubah. Proses Optimasi Hyperparameter dilakukan pada setiap desa yang akan diramalkan untuk mendapatkan parameter yang cocok untuk desa tersebut sehingga hasil peramalan menjadi optimal.

**Tabel 5.3 Hasil Optimasi Hyperparameter**

	1	2	3	4	5	6	7	8
	BoxConstraint	KernelScale	Epsilon	KernelFunction	PolynomialOrder	Standardize	Objective	Rank
1	1.0000e-03	1.0000e-03	0.0027	gaussian	NaN	true	0.0906	1377
2	1.0000e-03	1.0000e-03	0.0027	gaussian	NaN	false	0.0906	1375
3	1.0000e-03	1.0000e-03	0.0096	gaussian	NaN	false	0.0898	1224
4	1.0000e-03	1.0000e-03	0.0344	gaussian	NaN	false	0.0875	124
5	1.0000e-03	1.0000e-03	0.1237	gaussian	NaN	false	0.0888	1172
6	1.0000e-03	1.0000e-03	0.4444	gaussian	NaN	false	0.2066	1858
7	1.0000e-03	1.0000e-03	20.6268	gaussian	NaN	true	0.0887	808
8	1.0000e-03	0.0046	7.4129e-04	gaussian	NaN	true	0.0908	1508
9	1.0000e-03	0.0046	0.0027	gaussian	NaN	false	0.0906	1376
10	1.0000e-03	0.0046	0.0096	gaussian	NaN	true	0.0898	1223
11	1.0000e-03	0.0046	0.1237	gaussian	NaN	true	0.0888	1168

### 5.3 Cross Validation

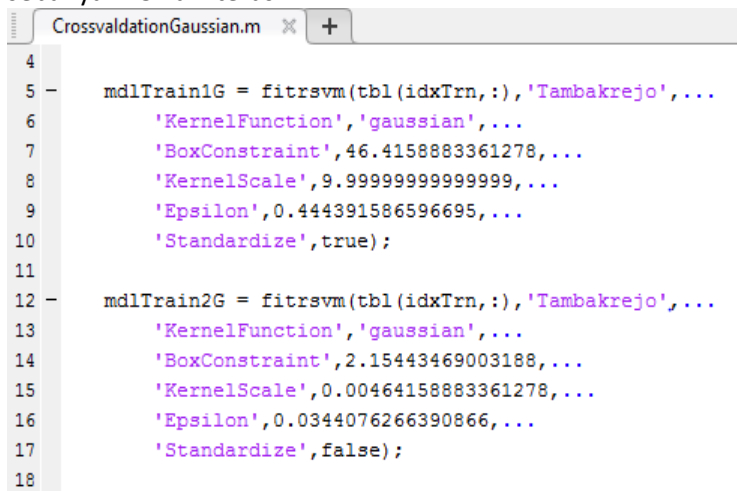
Cross Validation berfungsi untuk melakukan pemilihan model dan mencari nilai error untuk setiap model [27] dan untuk menghindari overfitting [28]. 5 parameter terbaik untuk setiap kernel pada proses optimasi hyperparameter di setiap desa akan dilakukan validasi silang dengan output nilai loss e-insensitif.

Input Cross Validation dapat dilihat pada tabel 5.4. pada gambar 5.2 terdapat pengelompokan berdasarkan jenis kernel yang dipakai yaitu kernel Gaussian, kernel polynomial dan kernel linear. Untuk masing – masing kernel terdapat 5 parameter terbaik dari hasil pencarian menggunakan gridsearch. Kelima parameter tersebut akan di bandingkan pada tahap ini dengan mencari nilai cross vaidation loss terkecil. Pada kernel gaussian terdapat nilai polynomialOrder parameter NaN yang berarti tidak ada parameter, hal ini dikarenakan parameter polynomial Order hanya berlaku di kernel polynomial, sebaliknya dengan kernel polynomial yang memiliki nilai NaN pada nilai parameter kernel scale, hal ini dikarenakan parameter polynomial tidak membutuhkan skala kernel.

**Tabel 5.4 Input Cross Validation**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standardize	Objektif (R <sup>2</sup> )
46.41588834	10	0.444392	'gaussian'	NaN	'true'	0.419641
2.15443469	0.004642	0.034408	'gaussian'	NaN	'false'	0.419679
1000	215.4435	0.444392	'gaussian'	NaN	'false'	0.419744
0.001	10	0.444392	'gaussian'	NaN	'false'	0.419758
0.021544347	1000	0.444392	'gaussian'	NaN	'false'	0.419759
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standardize	Objektif (R <sup>2</sup> )
0.004641589	NaN	0.444392	'polynomial'	3	'true'	0.408621
0.001	NaN	0.444392	'polynomial'	3	'true'	0.418697
0.464158883	NaN	0.444392	'polynomial'	2	'true'	0.419374
1000	NaN	0.444392	'polynomial'	2	'true'	0.419658
10	NaN	0.444392	'polynomial'	2	'true'	0.419708
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standardize	Objektif (R <sup>2</sup> )
1000	NaN	0.444392	'linear'	NaN	'true'	0.419752
215.443469	NaN	0.444392	'linear'	NaN	'false'	0.419753
10	NaN	0.444392	'linear'	NaN	'false'	0.419757
46.41588834	NaN	0.444392	'linear'	NaN	'false'	0.419758
0.021544347	NaN	0.444392	'linear'	NaN	'true'	0.419759

Source Code Input Cross Validation dapat dilihat pada Kode Program 5.2. pada kode program terlihat bahwa kode program yang dimasukkan adalah untuk kernel gaussian dengan model mdlTrain1G menyesuaikan dengan input parameter 1 di desa Tambakrejo, jika ingin menginputkan data di desa lain kita hanya perlu mengganti Tambakrejo di line 5 dengan nama desa lain misalnya Sitiarjo, untuk jenis kernel gaussian dengan nilai KernelFunction = gaussian, jika kita ingin memasukkan data pada kernel polynomia maka input KernelFunction tinggal diganti polynomial. Box Constraint = 46.41588834 , KernelScale = 9.99999999 , epsilon = 0.444391586596695 dan standarisasi = true. Begitu juga dengan mdlTrain2G yang akan memasukkan input parameter 2 pada kernel gaussian di desa tambakrejo. Proses ini dilakukan berulang kali untuk kernel yang berbeda di desa yang berbeda sehingga dapat disimpulkan bahwa proses memasukkan input ini dilakukan sebanyak 75 kali iterasi.



```

4
5 - mdlTrain1G = fitcsvm(tbl(idxTrn,:), 'Tambakrejo', ...
6     'KernelFunction', 'gaussian', ...
7     'BoxConstraint', 46.4158883361278, ...
8     'KernelScale', 9.999999999999999, ...
9     'Epsilon', 0.444391586596695, ...
10    'Standardize', true);
11
12 - mdlTrain2G = fitcsvm(tbl(idxTrn,:), 'Tambakrejo', ...
13    'KernelFunction', 'gaussian', ...
14    'BoxConstraint', 2.15443469003188, ...
15    'KernelScale', 0.00464158883361278, ...
16    'Epsilon', 0.0344076266390866, ...
17    'Standardize', false);
18

```

**Kode Program 5.2 Input Cross Validation**

Source Code untuk processing dan menyimpan hasil Loss dapat dilihat pada kode program 5.3. dari kode program dapat dilihat bahwa pada line 41 sampai 45 nilai fold pada cross validation adalah 4, hal ini dikarenakan untuk menyamakan jumlah data di setiap fold dengan data testing yaitu 20 dengan harapan bahwa akurasi peramalan data testing atau validasi menjadi lebih akurat. Perbedaan pada line 41 dan 42 adalah pada line 41 inputnya adalah model parameter 1 sedangkan line 42 adalah input untuk model parameter 2 sehingga data hasil cross validation pada kernel gaussian dapat dikeluarkan secara bersamaan. Pada line 48 terdapat fungsi KfoldLoss yang berfungsi untuk mencari loss atau rata-rata error pada setiap fold [29]. nilai loss pada setiap parameter akan dibandingkan dan dicari parameter yang memiliki nilai loss terkecil yang nantinya akan menjadi parameter terbaik pada jenis kernel yang pada kasus ini adalah gaussian. Hasil parameter terbaik pada setiap jenis kernel nantinya akan dibandingkan pada tahap selanjutnya.

```

41 - CVMdlTrain1G = crossval(mdlTrain1G,'KFold',4);
42 - CVMdlTrain2G = crossval(mdlTrain2G,'KFold',4);
43 - CVMdlTrain3G = crossval(mdlTrain3G,'KFold',4);
44 - CVMdlTrain4G = crossval(mdlTrain4G,'KFold',4);
45 - CVMdlTrain5G = crossval(mdlTrain5G,'KFold',4);
46
47
48 - lossG = table(kfoldLoss(CVMdlTrain1G),kfoldLoss(CVMdlTrain2G),kfoldLoss(CVMdlTrain3G),...
49             kfoldLoss(CVMdlTrain4G),kfoldLoss(CVMdlTrain5G));
50

```

**Kode Program 5.3 Proses dan Menyimpan Hasil Cross Validation**

Output Cross Validation dapat dilihat pada tabel 5.5. pada gambar dapat dilihat di kanan objektif adalah hasil cross validation dengan nilai loss terkecil pada kernel gaussian adalah 0.162293 yaitu pada parameter 1, berarti parameter 1 akan digunakan untuk peramalan data testing dan training yang nanti hasilnya akan dibandingkan dengan parameter 5 pada kernel polynomial dan parameter 1 pada kernel linear.

**Tabel 5.5 Output Cross Validation**

Box Constrain	Kernel Sc	Epsilon	Kernel	Polynomi	Standaris	Objektif	Crossvalidation loss
46.41588834	10		'gaussian'	NaN	'true'	0.419641	0.162293
2.15443469	0.004642	0.034408	'gaussian'	NaN	'false'	0.419679	0.513602
1000	215.4435	0.444392	'gaussian'	NaN	'false'	0.419744	0.190991
0.001	10	0.444392	'gaussian'	NaN	'false'	0.419758	0.521363
0.021544347	1000	0.444392	'gaussian'	NaN	'false'	0.419759	0.521594
Box Constrain	Kernel Sc	Epsilon	Kernel	Polynomi	Standaris	Objektif	Crossvalidation loss
0.004641589	NaN	0.444392	'polynomi	3	'true'	0.408621	0.207989
0.001	NaN	0.444392	'polynomi	3	'true'	0.418697	0.210316
0.464158883	NaN	0.444392	'polynomi	2	'true'	0.419374	0.185909
1000	NaN	0.444392	'polynomi	2	'true'	0.419658	0.18338
10	NaN	0.444392	'polynomi	2	'true'	0.419708	0.182516
Box Constrain	Kernel Sc	Epsilon	Kernel	Polynomi	Standaris	Objektif	Crossvalidation loss
1000	NaN	0.444392	'linear'	NaN	'true'	0.419752	0.170317
215.443469	NaN	0.444392	'linear'	NaN	'false'	0.419753	0.170578
10	NaN	0.444392	'linear'	NaN	'false'	0.419757	0.170836
46.41588834	NaN	0.444392	'linear'	NaN	'false'	0.419758	0.168488
0.021544347	NaN	0.444392	'linear'	NaN	'true'	0.419759	0.185317

## 5.4 Peramalan Data

Setelah mendapatkan parameter terbaik untuk masing - masing kernel maka langkah selanjutnya adalah dilakukan peramalan terhadap data training dan testing jumlah kasus demam berdarah di Kabupaten Malang. Setelah mendapatkan model terbaik dari validasi (peramalan data Testing maka selanjutnya akan dilakukan peramalan data 1 tahun kedepan

### 5.4.1 Peramalan Data Training

Peramalan data training digunakan untuk menerapkan model yang telah didapatkan dari tahapan cross validation pada data pelatihan untuk mengetahui tingkat keakuratan peramalan dari model. Kode Program 5.4 merupakan kode program untuk menerapkan model pada data pelatihan

```

ForecastGaussian.m  x +
9 - mdlTrainG = fitrsvm(tbl(idxTrn,:), 'Sitiarjo', ...
10     'KernelFunction', 'gaussian', ...
11     'BoxConstraint', 9.999999999999999, ...
12     'KernelScale', 0.464158883361278, ...
13     'Epsilon', 0.0344076266390866, ...
14     'Standardize', true);
15
16 - CVMdlTrainG = crossval(mdlTrainG, 'Kfold', 4);
17 - ModelG = CVMdlTrainG.Trained{1}
18
19 - trainfitG = abs(predict(ModelG, tbl(idxTrn,:)));
20 - trainpredictG = round(trainfitG);
21
22 - trainG = table(Sitiarjo(idxTrn,:), trainpredictG, 'VariableNames', ...
23     {'ObservedValue', 'PredictedValue'})
24

```

#### Kode Program 5.4 Peramalan kernel Gaussian pada data training

Pada kode program 5.4 line 9 berguna untuk menentukan dataset apa yang akan diramalkan, dalam kasus ini adalah dataset jumlah kasus demam berdarah di desa Sitiarjo. Pada line 10 - 14 merupakan input parameter terbaik untuk kernel gaussian di desa sitiarjo seperti yang dijelaskan pada tahap crossvalidation. Pada line 16 dilakukan crossvalidation untuk menentukan alpha yang optimal. Pada line 17 berguna untuk membuat data menjadi data utuh setelah dipartisi pada line 16. Kode program pada line 19 fungsi abs() berguna untuk membuat data peramalan bernilai positif karena jumlah kasus demam berdarah tidak mungkin bernilai negatif, fungsi predict berguna untuk melakukan forecasting. Pada kode line 21 berguna untuk menyimpan hasil peramalan data training yang nantinya akan dihitung SMAPE, MSE dan MAD pada bab 6.

### 5.4.2 Peramalan Data Testing

Model yang didapatkan dari hasil training model juga akan diterapkan pada data pengujian yang bertujuan untuk memastikan apakah model bisa diterapkan pada data yang lain sebagai bentuk uji validitas. Model terbaik dari hasil uji validitas akan diterapkan pada peramalan data kedepan. Kode Program 5.5 merupakan kode program untuk menerapkan model pada data pengujian.

```

ForecastGaussian.m  X  +
9 - mdlTrainG = fitrsvm(tbl(idxTrn,:), 'Sitiarjo', ...
10   'KernelFunction', 'gaussian', ...
11   'BoxConstraint', 9.999999999999999, ...
12   'KernelScale', 0.464158883361278, ...
13   'Epsilon', 0.0344076266390866, ...
14   'Standardize', true);
15
16 - CVMdlTrainG = crossval(mdlTrainG, 'Kfold', 4);
17 - ModelG = CVMdlTrainG.Trained{1}
18
19 - trainfitG = abs(predict(ModelG, tbl(idxTrn,:)));
20 - trainpredictG = round(trainfitG);
21
22 - trainG = table(Sitiarjo(idxTrn,:), trainpredictG, 'VariableNames', ...
23   {'ObservedValue', 'PredictedValue'});
24
25 - testfitG = abs(predict(ModelG, tbl(idxTest,:)));
26 - testpredictG = round(testfitG);
27
28 - testG = table(Sitiarjo(idxTest), testpredictG, 'VariableNames', ...
29   {'ObservedValue', 'PredictedValue'});

```

**Kode Program 5.5 Peramalan menggunakan Kernel Gaussian pada data Testing**

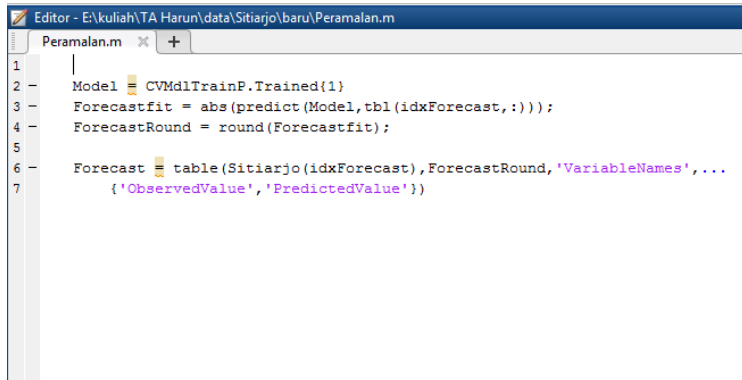
Pada kode program 5.5 dapat dilihat bahwa kode program data testing dapat disatukan dengan data training karena model data testing dan data training sama sehingga pada tahap ini tidak perlu mencari model baru lagi. Line 9 – 23 sudah dijelaskan pada tahap peramalan data training di subbab 5.4.1 yang berguna untuk melakukan training model dan mengeluarkan data hasil peramalan data training.

Pada line 25 terdapat idxTest yang berfungsi untuk menunjukkan data yang diramalkan adalah data testing berbeda dengan line 23 yang menggunakan idxTrn.



### 5.4.3 Peramalan 1 Tahun kedepan

Model terbaik yang didapatkan dari hasil validitas akan digunakan untuk melakukan peramalan 1 tahun kedepan. Kode Program 5.5 merupakan kode program untuk menerapkan model pada peramalan 1 tahun kedepan.



```

1
2 Model = CVMdlTrainP.Trained{1};
3 Forecastfit = abs(predict(Model,tbl(idxForecast,:)));
4 ForecastRound = round(Forecastfit);
5
6 Forecast = table(Sitiarjo(idxForecast),ForecastRound,'VariableNames',...
7                 {'ObservedValue','PredictedValue'})

```

#### Kode Program 5.6 Peramalan 1 tahun kedepan menggunakan Kernel Polynomial di desa Sitiarjo

Karena kernel Polynomial memiliki nilai error terendah pada saat validasi maka peramalan di desa Sitiarjo menggunakan kernel polynomial.

Pada Kode Program 5.6 dapat dilihat bahwa kode program ini tidak berbeda jauh dengan kode program training dan testing, Perbedaanya terletak pada Line 3 yaitu IdxForecast, pada IdxForecast berbeda dengan IdxTrn yang langsung memiliki nilai 1 pada indeks 1- 84 dan nilai 0 pada indeks 85 – 104. Idx Forecast ini perlu memasukkan data satu persatu yaitu pada index 105 dengan nilai 1 dan perlu juga memasukkan data curah hujan, kelembapan,suhu dan data aktual desa Sitiarjo pada indeks 105.

Data aktual desa Sitiarjo pada indeks 105 didapatkan dari peramalan pada indeks 104

*Halaman sengaja dikosongkan*

## **BAB VI**

### **HASIL DAN PEMBAHASAN**

Bab ini berisikan hasil dan pembahasan setelah melakukan implementasi. Hasil yang akan dijelaskan adalah hasil cross validation yang menghasilkan parameter terbaik pada setiap kernel di setiap desa, hasil uji coba model untuk mengetahui nilai SMAPE, MSE dan MAD pada setiap parameter terbaik yang telah dipilih pada cross validation, validasi model untuk mengetahui kelayakan model yang telah dibuat menggunakan data testing dan jika sudah menemukan model yang layak akan dilakukan peramalan, hasil peramalan untuk mengetahui perkiraan jumlah kasus demam berdarah pada periode yang akan datang.

#### **6.1 Hasil Grid Search**

Hasil pencarian grid search berupa parameter untuk setiap kernel di setiap desa, dari 2000 parameter yang didapatkan diambil 5 parameter terbaik untuk setiap kernel di setiap desa untuk dilakukan validasi untuk mencari parameter terbaik pada setiap kernel.

Berikut adalah hasil Grid search berdasarkan letak geografis di kabupaten malang:

##### **6.1.1 Dataran Tinggi**

Terdapat 2 Desa di Dataran Tinggi yaitu Desa Sitiarjo dan Tambakrejo berikut adalah hasil grid search dari setiap desa :

###### **6.1.1.1. Tambakrejo**

Tabel 6.1 merupakan tabel yang berisi 5 parameter terbaik untuk setiap kernel di desa Tambakrejo, pada tabel terdapat kolom param yang berarti parameter, parameter 1 pada kernel gaussian berbeda dengan parameter 1 pada kernel polynomial dan linear

**Tabel 6.1 5 Parameter Terbaik untuk setiap kernel di desa Tambakrejo**

Kernel Gaussian					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	46.4158	10	0.4443	NaN	'true'
Param2	2.1544	0.0046	0.0344	NaN	'false'
Param3	1000	215.4435	0.4443	NaN	'false'
Param4	0.001	10	0.4443	NaN	'false'
Param5	0.0215	1000	0.4443	NaN	'false'
Kernel Polynomial					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.0046	NaN	0.4443	3	'true'
Param2	0.001	NaN	0.4443	3	'true'
Param3	0.4641	NaN	0.4443	2	'true'
Param4	1000	NaN	0.4443	2	'true'
Param5	10	NaN	0.4443	2	'true'
Kernel Linear					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	1000	NaN	0.4443	NaN	'true'
Param2	215.4434	NaN	0.4443	NaN	'false'
Param3	10	NaN	0.4443	NaN	'false'
Param4	46.4158	NaN	0.4443	NaN	'false'
Param5	0.0215	NaN	0.4443	NaN	'true'

### 6.1.1.2. Sitiarjo

Tabel 6.2 merupakan tabel yang berisi 5 parameter terbaik untuk setiap kernel di desa Sitiarjo, pada tabel terdapat kolom param yang berarti parameter, parameter 1 pada kernel gaussian berbeda dengan parameter 1 pada kernel polynomial dan linear

**Tabel 6.2 5 Parameter Terbaik untuk setiap kernel di desa Sitiarjo**

Kernel Gaussian					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	1000	0.4642	0.0027	NaN	'true'
Param2	46.4159	0.4642	0.0027	NaN	'true'
Param3	10	0.4642	0.0096	NaN	'true'
Param4	1000	0.4642	0.0096	NaN	'true'
Param5	10	0.4642	0.0344	NaN	'true'
Kernel Polynomial					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.0046	NaN	0.1237	3.0000	'true'
Param2	0.0010	NaN	0.4444	3.0000	'true'
Param3	0.0215	NaN	0.4444	2.0000	'false'
Param4	0.0215	NaN	0.0027	4.0000	'false'
Param5	0.0046	NaN	5.7395	3.0000	'false'
Kernel Linear					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	1000	NaN	0.4444	NaN	'false'
Param2	10	NaN	0.4444	NaN	'true'
Param3	0.0010	NaN	0.4444	NaN	'false'
Param4	0.0010	NaN	5.7395	NaN	'true'
Param5	10	NaN	74.1290	NaN	'false'

## 6.1.2 Dataran Sedang

Terdapat 2 Desa di Dataran Sedang yaitu Desa Dalisodo dan Sumbermanjing Wetan berikut adalah hasil grid search dari setiap desa :

### 6.1.1.3. Dalisodo

Tabel 6.3 merupakan tabel yang berisi 5 parameter terbaik untuk setiap kernel di desa Dalisodo, pada tabel terdapat kolom param yang berarti parameter, parameter 1 pada kernel gaussian berbeda dengan parameter 1 pada kernel polynomial dan linear

**Tabel 6.3 Parameter Terbaik untuk setiap kernel di desa Dalisodo**

Kernel Gaussian					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	2.1544	0.4642	0.0007	NaN	'true'
Param2	215.4435	0.1000	0.0007	NaN	'true'
Param3	1,000	0.1000	0.0007	NaN	'true'
Param4	2.1544	0.1000	0.0007	NaN	false'
Param5	1,000	0.1000	0.0027	NaN	'true'
Kernel Polynomial					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	10	NaN	0.1237	2	'true'
Param2	46.4159	NaN	0.1237	2	'true'
Param3	215.4435	NaN	0.1237	2	'true'
Param4	0.0215	NaN	0.1237	2	'true'
Param5	0.4642	NaN	0.1237	2	'true'
Kernel Linear					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	215.4435	NaN	0.0344	NaN	'true'
Param2	1,000	NaN	0.1237	NaN	'true'
Param3	46.4159	NaN	0.0344	NaN	'true'
Param4	0.0010	NaN	0.0344	NaN	'true'
Param5	2.1544	NaN	0.0344	NaN	'true'

#### 6.1.1.4. Sumbermanjing Wetan

Tabel 6.4 merupakan tabel yang berisi 5 parameter terbaik untuk setiap kernel di desa Sumbermanjing Wetan, pada tabel terdapat kolom param yang berarti parameter, parameter 1 pada kernel gaussian berbeda dengan parameter 1 pada kernel polynomial dan linear

**Tabel 6.4 5 Parameter Terbaik untuk setiap kernel di desa Sumbermanjing Wetan**

Kernel Gaussian					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.0215	0.1000	0.0344	NaN	'false'
Param2	0.0215	0.0215	0.0344	NaN	'true'
Param3	0.0046	0.1000	0.0344	NaN	'true'
Param4	0.0046	0.0215	0.0344	NaN	'false'
Param5	0.0046	0.0046	0.0344	NaN	'true'
Kernel Polynomial					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.0010	NaN	0.0344	3	'true'
Param2	0.0046	NaN	0.0344	2	'true'
Param3	0.0215	NaN	0.0344	4	'false'
Param4	0.4642	NaN	1.5971	3	'true'
Param5	0.0046	NaN	0.4444	3	'false'
Kernel Linear					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	1000	NaN	0.0344	NaN	'false'
Param2	0.4642	NaN	0.0344	NaN	'false'
Param3	215.4435	NaN	0.0344	NaN	'false'
Param4	0.1000	NaN	0.0344	NaN	'false'
Param5	2.1544	NaN	0.0344	NaN	'false'

### 6.1.3 Dataran Rendah

Hanya terdapat 1 Desa di Dataran Rendah yaitu Desa Pandasari :

#### 6.1.1.5. Pandansari

Tabel 6.5 merupakan tabel yang berisi 5 parameter terbaik untuk setiap kernel di desa Pandansari, pada tabel terdapat kolom param yang berarti parameter, parameter 1 pada kernel gaussian berbeda dengan parameter 1 pada kernel polynomial dan linear

**Tabel 6.5 Parameter Terbaik untuk setiap kernel di desa Pandansari**

Kernel Gaussian					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.4642	0.4642	0.0344	NaN	'false'
Param2	0.4642	0.1000	0.0344	NaN	'false'
Param3	0.4642	0.0215	0.0344	NaN	'true'
Param4	0.4642	0.0215	0.0344	NaN	'false'
Param5	0.4642	0.0046	0.0344	NaN	'false'
Kernel Polynomial					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.0046	NaN	0.1237	3.0000	'true'
Param2	0.0046	NaN	0.0344	2.0000	'true'
Param3	0.0010	NaN	0.1237	3.0000	'true'
Param4	0.0046	NaN	0.0344	3.0000	'true'
Param5	0.0215	NaN	0.0344	2.0000	'true'
Kernel Linear					
Param	Box Constrain	Kernel Scale	Epsilon	Polynomial Order	Standarisasi
Param1	0.0010	NaN	0.0344	NaN	'true'
Param2	0.4642	NaN	0.0344	NaN	'false'
Param3	2.1544	NaN	0.0344	NaN	'true'
Param4	1000	NaN	0.0344	NaN	'true'
Param5	46.4159	NaN	0.0344	NaN	'false'

## 6.2 Hasil Cross Validation

Untuk menentukan parameter terbaik di setiap desa.pada setiap desa akan diambil 5 parameter hasil grid search berdasarkan pada jenis kernel gaussian, kernel polynomial dan linear kemudian dilakukan cross validation..Pembagaaian kelompok berdasarkan jenis kernel dikarenakan pemilihan jenis kernel merupakan parameter paling penting di metode Suport Vektor Regresi karena kernal merupakan parameter yang mengubah struktur dimensi non-linier menjadi linear agar dapat memfasilitasi model regresi dan algoritma untuk




mendapatkan akurasi dan efisiensi yang lebih tinggi [30]. Berikut adalah hasil perbandingan parameter pada setiap jenis kernel yang dipakai pada penelitian ini

### 6.2.1 Dataran Tinggi

Terdapat 2 Desa di Dataran Tinggi yaitu Desa Sitiarjo dan Tambakrejo berikut adalah hasil loss dari setiap desa :

#### 6.2.1.1 Tambakrejo


Pada gambar 6.1 dapat disimpulkan bahwa di desa Tambakrejo parameter 1 pada kernel gaussian merupakan parameter terbaik pada jenis kernel gaussian dan akan dipakai untuk uji coba model, pada jenis kernel polynomial parameter 5 merupakan parameter terbaik dan akan dipakai untuk uji coba model, pada kernel linear parameter 1 merupakan parameter terbaik yang akan dipakai untuk uji coba model.



**Gambar 6.1 Perbandingan Parameter pada setiap jenis kernel di Tambakrejo**

### 6.2.1.2 Sitiarjo

Pada gambar 6.2 dapat disimpulkan bahwa di desa Sitiarjo parameter 5 pada kernel gaussian merupakan parameter terbaik pada jenis kernel gaussian dan akan dipakai untuk uji coba model, pada jenis kernel polynomial parameter 3 merupakan parameter terbaik dan akan dipakai untuk uji coba model, pada kernel linear parameter 1 merupakan parameter terbaik yang akan dipakai untuk uji coba model.




**Gambar 6.2 Perbandingan Parameter pada setiap jenis kernel di Sitiarjo**

## 6.2.2 Dataran Sedang

Terdapat 2 Desa di Dataran Sedang yaitu Desa Dalisodo dan Sumbermanjing Wetan berikut adalah hasil loss dari setiap desa :

### 6.2.2.1 Dalisodo


Pada gambar 6.3 dapat disimpulkan bahwa di desa Dalisodo parameter 1 pada kernel gaussian merupakan parameter terbaik pada jenis kernel gaussian dan akan dipakai untuk uji coba model, pada jenis kernel polynomial parameter 4 merupakan parameter terbaik dan akan dipakai untuk uji coba model, pada kernel linear parameter 1 merupakan parameter terbaik yang akan dipakai untuk uji coba model.



**Gambar 6.3 Perbandingan Parameter pada setiap jenis kernel di Sitiarjo**

### 6.2.2.2 Sumbermanjing Wetan

Pada gambar 6.4 dapat disimpulkan bahwa di desa Sumbermanjing Wetan parameter 2 pada kernel gaussian merupakan parameter terbaik pada jenis kernel gaussian dan akan dipakai untuk uji coba model, pada jenis kernel polynomial parameter 1 merupakan parameter terbaik dan akan dipakai untuk uji coba model, pada kernel linear parameter 5 merupakan parameter terbaik yang akan dipakai untuk uji coba model.




**Gambar 6.4 Perbandingan Parameter pada setiap jenis kernel di Sumbermanjing Wetan**

### 6.2.3 Dataran Rendah

Terdapat 1 Desa di Dataran Rendah yaitu Desa Pandansari :

#### 6.2.3.1 Pandansari

Pada gambar 6.4 dapat disimpulkan bahwa di desa Pandansari parameter 4 pada kernel gaussian merupakan parameter terbaik pada jenis kernel gaussian dan akan dipakai untuk uji coba model, pada jenis kernel polynomial parameter 5 merupakan parameter terbaik dan akan dipakai untuk uji coba model, pada kernel linear parameter 2 merupakan parameter terbaik yang akan dipakai untuk uji coba model.



**Gambar 6.5 Perbandingan Parameter pada setiap jenis kernel di Pandansari**

### 6.3 Hasil Uji Coba Model

Pada tahapan ini, model yang telah didapatkan dari tahapan implementasi akan diterapkan pada data pelatihan untuk mengetahui tingkat keakuratan peramalan dari model. Hasil peramalan untuk data pelatihan terdapat pada Lampiran sedangkan hasil tingkat keakuratan uji coba model untuk semua desa terangkum pada Tabel 6.1

**Tabel 6.6 Hasil Uji Coba Model**

Dataran	Desa	Kernel	SMAPE	MSE	MAD
Tinggi	Tambakrejo	Gaussian	44.2%	0.807	0.566
		Polynomial	33.7%	0.711	0.470
		Linear	48.0%	0.807	0.614
	Sitiarjo	Gaussian	23.7%	0.880	0.398
		Polynomial	13.9%	0.506	0.241
		Linear	25.5%	0.651	0.361
Sedang	Dalisodo	Gaussian	10.0%	0.108	0.108
		Polynomial	18.1%	0.217	0.193
		Linear	22.9%	0.265	0.241
	Sumbermanjing Wetan	Gaussian	8.4%	0.084	0.084
		Polynomial	8.4%	0.084	0.084
		Linear	33.7%	0.337	0.337
Rendah	Pandansari	Gaussian	9.6%	0.133	0.108
		Polynomial	9.6%	0.133	0.108
		Linear	32.5%	0.361	0.337

Dari tabel 6.1 hasil ujicoba model dapat diketahui bahwa pada desa Tambakrejo kernel Polynomial merupakan kernel terbaik dengan nilai SMAPE 33.7%, pada desa Sitiarjo juga kernel Polynomial merupakan kernel terbaik dengan nilai SMAPE yaitu 13,9%, sedangkan pada desa Dalisodo kernel Gaussian merupakan kernel terbaik dengan nilai SMAPE 10%, dan desa Sumbermanjing Wetan memiliki kernel gaussian dan kernel polynomial sebagai kernel terbaik dengan nilai SMAPE 8,4%, di desa Pandasari kernel gaussian dan kernel polynomial juga merupakan kernel terbaik dengan nilai SMAPE 9,6%. Nilai kernel pada tahap ini digunakan sebagai pertimbangan jika kernel pada tahap validasi memiliki nilai error yang sama.

#### 6.4 Validasi Model

Pada tahapan ini, model yang didapatkan dari hasil implementasi juga akan diterapkan pada data pengujian yang bertujuan untuk memastikan apakah model bisa diterapkan pada data yang lain sebagai bentuk uji validitas. Apabila nilai SMAPE, MSE dan MAD kecil pada data pelatihan, menunjukkan bahwa model telah valid dan siap digunakan untuk meramalkan data.

**Tabel 6. 1 Hasil Validasi Model**

Dataran	Desa	Kernel	SMAPE	MSE	MAD
Tinggi	Tambakrejo	Gaussian	50.0%	0.950	0.650
		Polynomial	26.7%	0.600	0.400
		Linear	46.7%	0.950	0.650
	Sitiarjo	Gaussian	35.0%	0.500	0.400
		Polynomial	30.0%	0.450	0.350
		Linear	30.0%	0.450	0.350
Sedang	Dalisodo	Gaussian	20.0%	0.200	0.200
		Polynomial	25.0%	0.250	0.250
		Linear	25.0%	0.250	0.250
	Sumbermanjing Wetan	Gaussian	35.0%	0.500	0.400
		Polynomial	30.0%	0.450	0.350
		Linear	50.0%	0.650	0.550
Rendah	Pandansari	Gaussian	25.0%	0.250	0.250
		Polynomial	20.0%	0.200	0.200
		Linear	40.0%	0.400	0.400

Dari tabel 6.2 hasil Validasi model dapat diketahui bahwa pada desa Tambakrejo kernel Polynomial merupakan kernel terbaik dengan nilai SMAPE 26.7%, pada desa Sitiarjo juga kernel Polynomial dan Linear merupakan kernel terbaik dengan nilai SMAPE yaitu 30.0% maka hasil error pada tahap uji coba model diperhitungkan dengan kernel terbaik yaitu Polynomial, sedangkan pada desa Dalisodo kernel Gaussian merupakan kernel terbaik dengan nilai SMAPE 20%, dan desa Sumbermanjing Wetan memiliki kernel kernel polynomial sebagai kernel terbaik dengan nilai SMAPE 30%, di desa Pandasari kernel polynomial juga merupakan kernel terbaik dengan nilai SMAPE 20%. Nilai kernel terbaik pada tahap ini digunakan sebagai paramer untuk melakukan peramalan.

### 6.5 Parameter yang digunakan untuk Peramalan

Dari hasil Validasi model ditemukan parameter terbaik yang akan digunakan untuk melakukan peramalan, Tabel 6.3 merupakan tabel yang menunjukkan berapa nilai parameter yang digunakan di masing – masing desa.

**Tabel 6.3 Parameter untuk Peramalan**

Parameter	Tambakrejo	Sitiarjo	Dalisodo	Sumbermanjing Wetan	Pandansari
Box Constrain	10	0.0215	2.1544	0.001	0.0046
Kernel Scale	NaN	NaN	0.4642	NaN	NaN
Epsilon	0.444392	0.4444	0.0007	0.034408	0.1237
Kernel	'polynom'	'polynom'	'gaussian'	'polynomial'	'polynomial'
Polynomial Order	2	2	NaN	3	3
Standarisasi	'true'	'false'	'true'	'true'	'true'

Dari tabel 6.2 dapat dilihat bahwa kernel yang mendominasi adalah kernel polynomial dengan jumlah 4 desa, sedangkan kernel gaussian digunakan untuk meramalkan 1 desa yaitu Dalisodo, akan tetapi Kernel Linear kurang cocok digunakan untuk seluruh desa karena fungsi kernel lainnya memiliki hasil yang lebih baik dari kernel Linear, hal ini kemungkinan dikarenakan kernel Linear memiliki pola garis lurus sehingga kernel Linear lebih cocok digunakan untuk klasifikasi data daripada digunakan untuk peramalan.

### 6.6 Hasil Peramalan dan Analisa

Pada tahapan peramalan menggunakan SVR dilakukan dengan model yang didapatkan pada bab 6.4 Parameter yang digunakan, yaitu model hasil validasi. Model ini akan digunakan untuk meramalkan jumlah kasus demam berdarah pada tahun 2018, karena data aktual untuk curah hujan, kelembapan dan suhu tahun 2018 pada sudah tersedia dari website BMKG maka untuk data aktual yang akan




digunakan dalam analisa hasil peramalan menggunakan data tersebut dan tidak perlu dilakukan peramalan untuk memperpanjang data. Sehingga kita dapat langsung meramalkan data jumlah kasus demam berdarah.

### 6.6.1 Dataran Tinggi

Terdapat 2 Desa di Dataran Tinggi yaitu Desa Sitiarjo dan Tambakrejo berikut adalah hasil loss dari setiap desa :

#### 6.6.1.1 Tambakrejo

Didesa Tambakrejo Jumlah Kasus Demam Berdarah cenderung tinggi pada minggu 12 – 31 dengan jumlah kasus yang didominasi angka 2, kemudian pada minggu 33 – 45 yang cenderung konstan di angka 0, kemudian minggu 46 – 84 cenderung flutuatif. Pola data training yang dari tinggi kemudian kerendah kemudian kembali ketinggian kemungkinan menyebabkan optimasi parameter memilih polynomial order 2 sebagai parameter yang optimal




Gambar 6.6 Hasil Peramalan Tambakrejo

Dari gambar 6.6 dapat disimpulkan bahwa peramalan data tahun 2018 bersifat sangat fluktuatif, dengan nilai cenderung rendah atau 0 di minggu 115 – 129 dan cukup tinggi di awal dan akhir tahun. Hal ini kemungkinan disebabkan karena nilai polynomial order = 2 sehingga pola data dari tinggi kemudian turun kemudian naik.

### 6.6.1.2 Sitiarjo

Didesa Sitiarjo memiliki jumlah kasus demam berdarah yang tinggi di awal tahun 2016 yaitu minggu 1 – 30 kemudian turun drastis di minggu 31 – 40. Jumlah kasus demam berdarah di Desa Sitiarjo dan Tambakrejo dapat dikatakan fluktuatif hal ini kemungkinan disebabkan karena berada dalam 1 daerah yaitu dataran tinggi



**Gambar 6.7 Hasil Peramalan Desa Sitiarjo**


Dari gambar 6.7 dapat disimpulkan bahwa kemampuan Suport Vektor Regresi menggunakan kernel polynomial dalam memprediksi angka secara akurat cukup lemah, hal ini dapat disebabkan oleh kemungkinan bahwa variabel independen yang dipertimbangkan kurang pas sehingga sangat mempengaruhi hasil peramalan. Kenaikan data pada minggu 152 – 154 kemungkinan disebabkan karena curah hujan yang tinggi dan pola polynomial 2 pada akhir data akan naik sehingga menyebabkan peramalan naik pada minggu tersebut.

### 6.6.2 Dataran Sedang

Terdapat 2 Desa di Dataran Sedang yaitu Desa Dalisodo dan Sumbermanjing Wetan berikut adalah hasil loss dari setiap desa :

#### 6.6.2.1 Dalisodo

Di desa Dalisodo memiliki jumlah kasus yang rendah di minggu 1 – 47 dan naik pada minggu 48 – 74. Fluktuasi data pada kasus demam berdarah di desa Dalisodo cenderung rendah.




**Gambar 6.8 Peramalan di Desa Dalisodo**

Dari gambar 6.8 dapat disimpulkan bahwa kemampuan Suport Vektor Regresi menggunakan kernel gaussian dapat mengikuti pola data pada data training, hal ini dikarenakan nilai bobot  $\gamma=1$  dan variabel curah hujan yang cukup besar oleh karena itu dapat disimpulkan bahwa relasi dengan variabel independen sangat berpengaruh terhadap hasil peramalan.

### 6.6.2.2 Sumbermanjing Wetan

Di desa Sumbermanjing Wetan memiliki jumlah kasus yang rendah di minggu 1 – 67 dan naik pada minggu 69 – 86. Fluktuasi data pada kasus demam berdarah di desa Sumbermanjing Wetan cenderung tinggi di tahun 2017.



**Gambar 6.9 Peramalan Data di Desa Sumbermanjing Wetan**


Dari gambar 6.9 dapat disimpulkan bahwa tipe data seperti di Sumbermanjing Wetan sangat susah untuk dilakukan peramalan yang akurat, hal ini dikarenakan kebanyakan fluktuasi data berada pada data testing sehingga susah untuk mendapatkan model yang optimal. Kenaikan peramalan di minggu 153 dan 154 kemungkinan dikarenakan jumlah curah hujan yang tinggi sehingga data peramalan menjadi meningkat.

### 6.6.3 Dataran Rendah

Terdapat 1 Desa di Dataran Rendang yaitu Desa Pandansari :

#### 6.6.3.1 Pandansari

Di desa Sumbermanjing Wetan memiliki jumlah kasus yang rendah di minggu 1 – 52 dan naik pada minggu 53 – 73. Fluktuasi data pada kasus demam berdarah di desa Pandansari cenderung tinggi di awal tahun 2017.



**Gambar 6.10 Peramalan di Desa Pandansari**

Dari gambar 6.10 dapat disimpulkan bahwa fluktuasi data pada minggu 146 – 152 mengikuti pola data pada minggu 36 – 45. Hal ini kemungkinan dikarenakan nilai bobot kelembapan yang tinggi sehingga pada saat kelembapan rendah data prediksi akan naik, oleh karena itu diperlukan memilih variabel independen yang memiliki pola yang hampir sama atau berkaitan erat sehingga hasil peramalan menjadi jauh lebih baik

## 6.7 Kesimpulan Hasil Peramalan

Berdasarkan hasil peramalan pada tugas akhir ini, maka didapatkan kesimpulan sebagai berikut :

1. Peramalan jumlah kasus demam berdarah di desa selain dalisodo menggunakan kernel polynomial dan di desa dalisodo menggunakan kernel gaussian
2. Jenis kernel Linear tidak terlalu cocok digunakan untuk meramalkan jumlah kasus demam berdarah di kabupaten Malang
3. Pemilihan variabel bebas sangat mempengaruhi hasil peramalan
4. Pemilihan kernel yang tepat dibutuhkan untuk menyesuaikan pola peramalan dengan data aktual
5. Banyaknya kesalahan peramalan dikarenakan fluktuasi variabel independen yang tinggi yang berbeda dengan variabel terikat yang cenderung konstan
6. Kernel Polynomial akan baik di gunakan bila pola data memiliki fluktuasi yang hampir sama dengan pola polynomial order
7. Kernel gaussian akan baik digunakan jika  $y_t$  berhubungan erat dengan  $y_{t-1}$
8. Kernel linear akan baik digunakan jika pola data tidak terlalu fluktuatif karena jika fluktuasinya tinggi seperti di tambakrejo maka peramalan menggunakan kernel linear akan didominasi angka 1
9. Nilai total SMAPE, MSE dan MAD di desa Tambakrejo adalah 32,4%, 0.689, 0.456 ; desa Sitiarjo adalah 17%, 0.495, 0.262 ; desa Dalisodo adalah 12%, 0.126, 0.126 ; desa Sumbermanjing Wetan adalah 12.6%, 0.155, 0.136 ; dan desa Pandansari adalah 11.7%, 0.146, 0.126

## **BAB VII**

### **KESIMPULAN DAN SARAN**

Pada bab ini berisikan tentang kesimpulan yang didapatkan dari semua proses dan implementasi yang telah dilakukan serta berisikan saran untuk pengembangan penelitian selanjutnya yang lebih baik.

#### **7.1 Kesimpulan**

Berdasarkan hasil penelitian pada tugas akhir ini, maka didapatkan kesimpulan sebagai berikut :

1. Model Suport Vektor Regresi dapat digunakan untuk meramalkan jumlah kasus demam berdarah dikarenakan memiliki nilai error yang cukup dapat diterima
2. Hasil peramalan jumlah kasus demam berdarah di beberapa desa Kabupaten Malang pada periode selanjutnya memiliki nilai rata-rata SMAPE : 27.69%, rata-rata MAD : 0.33 dan rata-rata MSE : 0.44. Hasil peramalan ini dapat dibilang cukup baik

#### **7.2 Saran**

Berdasarkan hasil penelitian pada tugas akhir ini, maka saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut :

1. Menambah variabel independen yang memiliki relasi tinggi dengan variabel terikat misalkan penambahan penduduk
2. Untuk data yang berpola seperti Sumbermanjing Wetan diperlukan lebih banyak data seperti mengubah data dari mingguan ke harian agar data tidak cenderung fluktuatif di data testing saja
3. Menggunakan metode Optimasi yang lebih baik seperti Bayessian Optimation sehingga hasil peramalan menjadi lebih baik

*Halaman ini sengaja dikosongkan*



## DAFTAR PUSTAKA

- [1] S. A, "Demam Berdarah Dengue (DBD)," *Medula*, vol. 2, 2014.
- [2] J. Ariati and D. A. Musadad, "Kejadian Demam Berdarah Dengue (Dbd) Dan Faktor Iklim Di Kota Batam, Provinsi Kepulauan Riau," 2012.
- [3] W. Anggraeni, I. P. A. A. Pramana, F. Samopa, E. Riksakomara, R. P. Wibowo, L. C. T. and Pujiadi, "Forecasting The Number of Dengue Fever Cases in Malang Regency Indonesia Using Fuzzy Inference System Models," *Journal of Theoretical and Applied Information Technology*, 2017.
- [4] surabaya.tribunnews.com, "Jumlah Kasus Demam Berdarah di Jatim Menurun berkat Tiga Program ini," *tribunnews.com*, 8 February 2017. [Online]. Available: <http://surabaya.tribunnews.com/2017/02/08/jumlah-kasus-demam-berdarah-di-jatim-menurun-berkat-tiga-program-ini?page=2>. [Accessed 2 10 2018].
- [5] radarmalang.id, "Aduh, Semua Kelurahan Di Malang Rawan Demam Berdarah," *Jawa Pos*, 12 May 2017. [Online]. Available: <http://www.radarmalang.id/aduh-semua-kelurahan-di-malang-rawan-demam-berdarah/>. [Accessed 2 October 2018].
- [6] A. Abdillah, "Peramalan Jumlah Kasus Demam Berdarah Di Beberapa Desa Kabupaten Malang Menggunakan Metode Fuzzy Inference System," *POMITS*, 2018.
- [7] Y. Yusof and Z. Mustaffa, "Dengue Outbreak Prediction: A Least Squares Support Vector Machines Approach," *International Journal of Computer Theory and Engineering*, vol. 3, 2011.
- [8] Y. WU, IAENG, G. LEE, X. F. HUNG and Terence, "Detect Climatic Factors Contributing to Dengue Outbreak based on Wavelet, Support Vector Machines

- and Genetic Algorithm," *World Congress on Engineering*, vol. 1, 2008.
- [9] V. Rusmalawati, M. T. Furqon and Indriati, "Peramalan Harga Saham Menggunakan Metode Support Vector Regression (SVR) Dengan Particle Swarm Optimization (PSO)".
- [10] G.-F. Fan, L.-L. Peng, W.-C. Hong and F. Sun, "Electric load forecasting by the SVR model with differential empirical mode decomposition and auto regression," *ELSEVIER*, 2015.
- [11] P. X. Y. C. W. L. Y. W. L. N. Y. B. K. W. Yongbao Chen, "Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings," *Elsevier*, no. 195, pp. 659-670, 2017.
- [12] R. A. Yaffee and M. McGee, *Introduction to Time Series Analysis and Forecasting with Applications of SAS and SPSS*.
- [13] D. R. M. Gor, *Industrial Statistics And Operational Management*.
- [14] S. Andi Dirpan, "Metode Peramalan Kuantitatif Dengan Software Qm".
- [15] Wikipedia, "Regresi Linier Sederhana," Wikimedia Foundation, 21 1 2017. [Online]. Available: [https://id.wikipedia.org/wiki/Regresi\\_Linier\\_Sederhana](https://id.wikipedia.org/wiki/Regresi_Linier_Sederhana). [Accessed 28 9 2018].
- [16] M. Syafrudin, L. Hakim and D. Despa, "Metode Regresi Linier untuk Prediksi KebutuhanEnergi Listrik Jangka Panjang (Studi Kasus Provinsi Lampung)".
- [17] V. N. P. Hasan, W. F. Mahmudy and M. Z. Sarwani, "PEMODELAN REGRESI NON LINEAR MENGGUNAKAN ALGORITMA GENETIKA UNTUK PREDIKSI KEBUTUHAN AIR PDAM KOTA MALANG," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 2016.

- [18] R. Zunaidhi, W. S. J. Saputra and N. K. Sari, "APLIKASI PERAMALAN PENJUALAN MENGGUNAKAN METODE REGRESI LINIER".
- [19] W.-C. Hong, Y. Dong, F. Zheng and C.-Y. Lai, "Forecasting urban traffic flow by SVR with continuous ACO," *Applied Mathematical Modelling*, no. 35, pp. 1282-1291, 2011.
- [20] W.-C. Hong, "Traffic flow forecasting by seasonal SVR with chaotic simulated annealing algorithm," *Elsevier*, 2011.
- [21] A. J. Smola and B. Scholkopf, "A Tutorial on Support Vector Regression," *NeuroCOLT Technical Report Series*, 1998.
- [22] J. F. Rendon-Sanchez and L. M. d. Menezes, "Structural combination of seasonal exponential smoothing forecasts applied to load forecasting," *European Journal of Operational Research*, 2018.
- [23] R. Maharesi, "Penggunaan Support Vector Regression (Svr) Pada Prediksi Return Saham Syariah Bei," *Proceeding PESAT (Psikologi, Ekonomi, Sastra, Arsitektur & Teknik Sipil)*, 2013.
- [24] M. S. Bori, "Dealing with missing data: Key assumptions and," *Boston University Technical Report*, no. 4, 2013.
- [25] H. Xu, "LOCF Method and Application in Clinical Data Analysis," *NESUG*, 2009.
- [26] C.-C. C. a. C.-J. L. Chih-Wei Hsu, "A Practical Guide to Support Vector Classification," 2003.
- [27] D. K. Barrowa and S. F. Crone, "Cross-validation aggregation for combining autoregressive," *International Journal of Forecasting*, no. 32, pp. 1120-1137, 2016.
- [28] W. Lijuan and C. Guohua, "Seasonal SVR with FOA algorithm for single-step and multi-step ahead," *Knowledge-Based Systems*, no. 110, pp. 157 - 166, 2016.
- [29] The MathWorks Inc., "cross-validation loss of partitioned

regression model," The MathWorks Inc., [Online]. Available:

<https://www.mathworks.com/help/stats/regressionpartitionedmodel.kfoldloss.html>. [Accessed 09 1 2019].

- [30] Z. Zhang, G. Gao, Y. Tian and J. Yue, "Two-phase multi-kernel LP-SVR for feature sparsification and forecasting," *Neurocomputing*, no. 214, p. 594–606, 2016.

## BIODATA PENULIS



Penulis lahir di Jombang, 09 April 1996, dengan nama lengkap Mochamad Harun Hekmatyar. Penulis merupakan anak kedua dari tiga bersaudara. Riwayat pendidikan penulis yaitu SD Negeri Jombatan 5, SMP Negeri 2 Jombang, SMA Negeri 2 Jombang, dan akhirnya menjadi salah satu mahasiswa Sistem Informasi angkatan 2014 melalui jalur SNMPTN

dengan NRP 05211440000162

Penulis mengambil bidang minat Rekayasa Data dan Intelegensia Bisnis (RDIB) di Departemen Sistem Informasi ITS. Penulis dapat dihubungi melalui *email* [mochammad.harun@gmail.com](mailto:mochammad.harun@gmail.com)

*Halaman ini sengaja dikosongi*

**Lampiran A**

Data mentah Jumlah kasus Demam Berdarah per Desa per Pekan

No.	Sitiarjo	Tambakrejo	Dalisodo	Sumbermanjing Wetan	Pandansari
1	1	0	0	0	0
2	3	0	0	0	0
3	0	0	0	0	0
4	0	0	0	0	0
5	0	1	0	0	0
6	1	0	0	0	0
7	1	0	0	0	0
8	1	0	0	0	0
9	5	0	0	0	0
10	3	0	0	0	0
11	2	0	0	0	0
12	0	2	0	0	0
13	1	0	0	0	0
14	0	1	0	0	0
15	0	2	0	0	0
16	0	0	0	0	0
17	1	0	0	0	0
18	0	0	0	0	0
19	0	0	0	0	0
20	0	0	0	0	0
21	0	2	0	0	0
22	0	1	0	0	0
23	0	3	0	0	0
24	1	1	0	0	0
25	0	0	0	0	0
26	1	1	0	0	0
27	0	0	0	0	0
28	0	0	0	0	0
29	0	2	0	0	0
30	2	0	0	0	0
31	0	2	0	0	0
32	0	0	0	0	0
33	0	0	0	0	0

No.	Sitiarjo	Tambakrejo	Dalisodo	Sumbermanjing Wetan	Pandansari
34	0	0	0	0	0
35	0	0	0	0	0
36	0	0	0	0	0
37	0	0	0	0	0
38	0	0	0	0	0
39	0	0	0	0	0
40	0	0	0	0	0
41	0	0	0	0	0
42	0	0	0	0	0
43	0	1	0	0	0
44	1	2	0	0	0
45	0	0	0	0	0
46	0	0	0	0	0
47	0	1	0	0	0
48	0	0	0	0	0
49	0	0	0	0	0
50	0	0	0	0	0
51	0	0	0	0	0
52	0	0	0	0	0
53	0	0	1	0	0
54	0	0	2	1	0
55	0	2	1	0	0
56	0	0	0	0	1
57	0	0	0	0	0
58	0	0	0	0	2
59	1	0	0	0	1
60	0	0	1	0	0
61	0	0	0	0	0
62	0	0	0	0	1
63	0	1	0	0	0
64	0	0	0	0	0
65	0	0	0	0	0
66	0	0	0	0	0
67	0	0	0	0	0
68	0	2	0	0	0
69	0	0	0	0	0
70	0	0	0	1	0



No.	Sitiarjo	Tambakrejo	Dalisodo	Sumbermanjing Wetan	Pandansari
71	0	0	0	0	1
72	0	0	0	0	0
73	0	0	0	0	0
74	0	0	1	0	0
75	0	0	0	0	0
76	0	0	0	0	0
77	0	0	0	1	0
78	0	0	0	0	0
79	0	0	0	0	0
80	0	0	0	0	0
81	0	0	0	1	0
82	0	0	0	0	0
83	0	2	0	0	0
84	0	0	0	0	0
85	0	0	0	0	0
86	1	1	0	1	0
87	0	0	0	0	0
88	0	0	0	0	0
89	0	0	0	0	0
90	0	0	1	1	0
91	1	2	1	0	0
92	0	0	0	1	1
93	0	0	0	0	0
94	0	0	0	0	0
95	0	0	0	2	0
96	1	2	1	1	1
97	2	2	1	0	0
98	0	1	0	0	0
99	0	0	0	0	0
100	0	0	1	0	0
101	0	0	0	0	0
102	0	0	0	0	0
103	0	0	0	0	0
104	0	0	0	0	1

*Halaman sengaja dikosongkan*

**Lampiran B****Data Curah Hujan, Suhu, Dan Kelembaban**

No.	Suhu Avg	Kelembaban	Curah Hujan
1	25.35714	78.57143	7.085714
2	25.52857	79.57143	7.5
3	25.3	78.85714	11.15714
4	24.37143	82.85714	4.3
5	24.68571	85	20.57143
6	23.71429	91.42857	21.38571
7	24.4	85.28571	10.82857
8	24.1	84	29.85714
9	24.54286	85.14286	25.42857
10	25.12857	86.14286	8.5
11	24.9	81.71429	3.285714
12	24.81429	85.42857	7.557143
13	25.08571	83.57143	5.971429
14	25.07143	79.28571	6.028571
15	24.92857	84.57143	9.314286
16	25.37143	79.42857	0.383333
17	25.07143	79.28571	2.857143
18	25.44286	77.28571	0
19	24.82857	84.14286	17.08571
20	25.64286	78.85714	2
21	25.11429	78.28571	0.785714
22	24.17143	83	14.08571
23	24.28571	79.42857	1.685714
24	24.61429	77.57143	1.8
25	23.97143	81.14286	1.085714
26	23.71429	83.71429	12.85714
27	23.84286	77	9.914286
28	24.31429	79.71429	0.171429
29	23.71429	82.14286	0.542857
30	23.27143	78	3.485714
31	23	79.42857	1.642857
32	23.7	75.85714	0.028571
33	23.48571	81.42857	12.9
34	23.01429	72.42857	0
35	24.77143	74.42857	0
36	24.42857	74.28571	1.328571

No.	Suhu Avg	Kelembaban	Curah Hujan
37	23.82857	79	0.428571
38	25.52857	70.57143	0.042857
39	24.4	81.28571	11.18571
40	24.37143	82.14286	7.414286
41	24.62857	78.57143	18.18571
42	25.5	71.42857	0.5
43	24.54286	78.85714	11.2
44	25.12857	80.42857	2.1
45	24.68571	82.57143	18.85714
46	24.48571	84	12.12857
47	24.54286	84.42857	14.62857
48	24.32857	85.28571	22.55714
49	23.71429	88.57143	14.05714
50	23.34286	88	10.07143
51	25.58571	75.42857	9.157143
52	24.6	83.28571	0.114286
53	24.225	84.875	5.7
54	24.78571	82.57143	16.37143
55	23.65714	87.71429	10.02857
56	23.48571	87	22.85714
57	23.4	87.71429	17.18571
58	24.9	74.42857	7.557143
59	24.02857	84	10.01429
60	24.22857	84.85714	5.7
61	24.25714	82.71429	19.32857
62	24.15714	79.14286	9.242857
63	24.27143	83	5.657143
64	24.4	83.57143	6
65	23.62857	84.28571	25.15714
66	23.32857	88.42857	18.9
67	24.38571	82.42857	6.057143
68	24.44286	80.71429	4.785714
69	24.65714	79.71429	10.24286
70	24.55714	82.71429	2.642857
71	24.25714	76.42857	0.242857
72	24.3	71.28571	0
73	23.87143	71.14286	0
74	24.02857	85	4.985714

No.	Suhu Avg	Kelembaban	Curah Hujan
75	23.77143	76.57143	2.071429
76	24.02857	80.85714	0.985714
77	23.35714	75	0.085714
78	23.22857	78	1.385714
79	23.01429	77	0
80	22.58571	83.14286	0.671429
81	22.44286	77.42857	0.042857
82	22.34286	78	5.457143
83	21.94286	81.14286	0.314286
84	22.98571	78.71429	0
85	22.32857	75.14286	0.057143
86	22.97143	74.85714	0
87	22.78571	72.71429	0
88	23.54286	73	0
89	23.67143	74.28571	0.057143
90	23.65714	69.28571	0.985714
91	24.44286	77.14286	6
92	24.81429	76.71429	8.071429
93	25.21429	75.57143	3.3
94	24.48571	79.57143	2.114286
95	24.85714	76.57143	2.457143
96	24.75714	75	5.785714
97	25.42857	77.28571	6.671429
98	23.92857	84.71429	10.48571
99	23.8	87.85714	22.97143
100	23.64286	87.42857	26.17143
101	25.11429	79.57143	4.428571
102	24.14286	85.42857	9.371429
103	23.61429	87.57143	13.55714
104	24.18571	79.14286	2.157143
105	23.78571	85.14286	17.61429
106	23.37143	85.42857	25.54286
107	23.32857	87.71429	12.6
108	24.32857	84.57143	10.42857
109	23.81429	85.14286	10.42857
110	23.65714	84	13.27143
111	23.97143	84.14286	3.057143
112	23.68571	85.71429	7.585714

No.	Suhu Avg	Kelembaban	Curah Hujan
113	23.87143	81.85714	3.357143
114	23.95714	84.42857	15.21429
115	24	81.42857	4.857143
116	24.01429	79.14286	4.8
117	24.48571	81.71429	4.271429
118	24.54286	80.57143	5.271429
119	25.31429	76.42857	1.257143
120	24.88571	79	4.885714
121	24.74286	72.42857	3.2
122	23.67143	67.42857	0
123	24.27143	70.71429	0
124	24.12857	82.14286	0.471429
125	24.95714	78.14286	2.028571
126	23.25714	73.28571	0
127	23.84286	77	0
128	22.97143	74.14286	0
129	23.14286	83.28571	7.228571
130	22.52857	80.57143	0.514286
131	21.82857	75.28571	0
132	21.3	77.57143	0
133	22.44286	77.57143	1.328571
134	21.77143	70	0
135	21.31429	75.14286	0
136	22.05714	76.57143	0
137	22.04286	70.57143	0.057143
138	22.74286	68	0
139	23.15714	78	0
140	23.15714	75.57143	0
141	23.2	69.57143	0
142	24.37143	70.14286	0.471429
143	24.54286	64.85714	0
144	24.97143	63.57143	0
145	25.17143	67.71429	0
146	24.77143	73.28571	0.857143
147	25.65714	73	0.057143
148	25.7	69.28571	2.585714
149	24.94286	80.42857	7.357143
150	25.98571	76.28571	10.35714

No.	Suhu Avg	Kelembaban	Curah Hujan
151	24.88571	77.42857	12.77143
152	23.21429	90.42857	24.11429
153	24.72857	84	22.34286
154	24.51429	87.14286	23.3
155	23.77143	86.71429	5.828571
156	23.62857	85	3.571429





### Lampiran C

Lampiran C Hasil 100 parameter dari Grid Search

#### Tambakrejo

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.004642	NaN	0.444392	'polynomial'	3	'true'
0.004642	NaN	0.444392	'polynomial'	3	'true'
0.001	NaN	0.444392	'polynomial'	3	'true'
0.001	NaN	0.444392	'polynomial'	3	'true'
0.464159	NaN	0.444392	'polynomial'	2	'true'
46.41589	10	0.444392	'gaussian'	NaN	'true'
1000	NaN	0.444392	'polynomial'	2	'true'
1000	NaN	0.444392	'polynomial'	2	'true'
1000	NaN	0.444392	'polynomial'	2	'true'
2.154435	0.004642	0.034408	'gaussian'	NaN	'false'
2.154435	0.004642	0.034408	'gaussian'	NaN	'false'
10	NaN	0.444392	'polynomial'	2	'true'
1000	215.4435	0.444392	'gaussian'	NaN	'false'
1000	215.4435	0.444392	'gaussian'	NaN	'false'
1000	NaN	0.444392	'linear'	NaN	'true'
1000	NaN	0.444392	'linear'	NaN	'true'
1000	NaN	0.444392	'linear'	NaN	'true'
1000	NaN	0.444392	'linear'	NaN	'true'
1000	NaN	0.444392	'linear'	NaN	'false'
1000	NaN	0.444392	'linear'	NaN	'false'
1000	NaN	0.444392	'linear'	NaN	'false'
1000	NaN	0.444392	'linear'	NaN	'false'
215.4435	NaN	0.444392	'linear'	NaN	'false'
10	NaN	0.444392	'linear'	NaN	'false'
10	NaN	0.444392	'linear'	NaN	'false'
10	NaN	0.444392	'linear'	NaN	'false'
10	NaN	0.444392	'linear'	NaN	'false'
46.41589	NaN	0.444392	'linear'	NaN	'false'
46.41589	NaN	0.444392	'linear'	NaN	'false'
0.001	10	0.444392	'gaussian'	NaN	'false'
0.021544	1000	0.444392	'gaussian'	NaN	'false'
0.021544	NaN	0.444392	'linear'	NaN	'true'
0.464159	NaN	0.444392	'linear'	NaN	'true'
0.464159	NaN	0.444392	'linear'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.464159	NaN	0.444392	'linear'	NaN	'true'
0.464159	NaN	0.444392	'linear'	NaN	'true'
0.1	1000	0.444392	'gaussian'	NaN	'true'
10	1000	0.444392	'gaussian'	NaN	'true'
0.464159	215.4435	0.444392	'gaussian'	NaN	'true'
0.464159	1000	0.444392	'gaussian'	NaN	'false'
10	215.4435	0.444392	'gaussian'	NaN	'true'
0.021544	46.41589	0.444392	'gaussian'	NaN	'true'
46.41589	NaN	0.444392	'linear'	NaN	'true'
46.41589	NaN	0.444392	'linear'	NaN	'true'
46.41589	NaN	0.444392	'linear'	NaN	'true'
46.41589	NaN	0.444392	'linear'	NaN	'true'
0.1	46.41589	0.444392	'gaussian'	NaN	'true'
2.154435	NaN	0.444392	'linear'	NaN	'false'
2.154435	NaN	0.444392	'linear'	NaN	'false'
2.154435	NaN	0.444392	'linear'	NaN	'false'
2.154435	NaN	0.444392	'linear'	NaN	'false'
2.154435	NaN	0.444392	'linear'	NaN	'false'
2.154435	NaN	0.444392	'linear'	NaN	'false'
0.1	NaN	0.444392	'linear'	NaN	'false'
0.001	NaN	0.444392	'linear'	NaN	'true'
0.001	NaN	0.444392	'linear'	NaN	'true'
0.004642	NaN	0.444392	'linear'	NaN	'true'
0.004642	NaN	0.444392	'linear'	NaN	'true'
0.004642	NaN	0.444392	'linear'	NaN	'true'
46.41589	1000	0.444392	'gaussian'	NaN	'false'
2.154435	0.004642	0.009574	'gaussian'	NaN	'false'
2.154435	0.001	0.009574	'gaussian'	NaN	'false'
2.154435	46.41589	0.444392	'gaussian'	NaN	'true'
0.021544	46.41589	0.444392	'gaussian'	NaN	'false'
215.4435	NaN	0.444392	'linear'	NaN	'true'
2.154435	NaN	0.444392	'linear'	NaN	'true'
2.154435	NaN	0.444392	'linear'	NaN	'true'
2.154435	NaN	0.444392	'linear'	NaN	'true'
2.154435	NaN	0.444392	'linear'	NaN	'true'
0.1	46.41589	0.444392	'gaussian'	NaN	'false'
10	NaN	0.444392	'linear'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
10	NaN	0.444392	'linear'	NaN	'true'
10	NaN	0.444392	'linear'	NaN	'true'
0.464159	NaN	0.444392	'linear'	NaN	'false'
0.464159	NaN	0.444392	'linear'	NaN	'false'
0.464159	NaN	0.444392	'linear'	NaN	'false'
0.464159	46.41589	0.444392	'gaussian'	NaN	'false'
215.4435	46.41589	0.444392	'gaussian'	NaN	'false'
215.4435	46.41589	0.444392	'gaussian'	NaN	'false'
0.001	0.004642	0.444392	'gaussian'	NaN	'false'
0.001	0.001	0.444392	'gaussian'	NaN	'false'
0.001	0.1	0.444392	'gaussian'	NaN	'true'
0.1	NaN	0.444392	'linear'	NaN	'true'
0.1	NaN	0.444392	'linear'	NaN	'true'
0.1	NaN	0.444392	'linear'	NaN	'true'
0.1	NaN	0.444392	'linear'	NaN	'true'
0.1	NaN	0.444392	'linear'	NaN	'true'
2.154435	0.001	0.002664	'gaussian'	NaN	'true'
2.154435	0.001	0.002664	'gaussian'	NaN	'false'
2.154435	0.001	0.000741	'gaussian'	NaN	'false'
215.4435	NaN	0.444392	'polynomial'	2	'true'
215.4435	NaN	0.444392	'polynomial'	2	'true'
215.4435	NaN	0.444392	'polynomial'	2	'true'
215.4435	46.41589	0.444392	'gaussian'	NaN	'true'
2.154435	0.004642	0.000741	'gaussian'	NaN	'true'
0.004642	NaN	0.444392	'linear'	NaN	'false'
0.004642	NaN	0.444392	'linear'	NaN	'false'
0.004642	NaN	0.444392	'linear'	NaN	'false'
0.004642	NaN	0.444392	'polynomial'	2	'true'
0.004642	NaN	0.444392	'polynomial'	2	'true'

### Sitirejo

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
1000.0000	0.4642	0.0027	'gaussian'	NaN	'true'
46.4159	0.4642	0.0027	'gaussian'	NaN	'true'
10.0000	0.4642	0.0096	'gaussian'	NaN	'true'
1000.0000	0.4642	0.0096	'gaussian'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
10.0000	0.4642	0.0344	'gaussian'	NaN	'true'
46.4159	0.4642	0.0344	'gaussian'	NaN	'true'
46.4159	0.4642	0.0344	'gaussian'	NaN	'true'
0.4642	0.4642	0.1237	'gaussian'	NaN	'true'
0.4642	0.4642	0.1237	'gaussian'	NaN	'true'
1000.0000	46.4159	0.4444	'gaussian'	NaN	'false'
1000.0000	NaN	0.4444	'linear'	NaN	'false'
1000.0000	NaN	0.4444	'linear'	NaN	'false'
1000.0000	NaN	0.4444	'linear'	NaN	'false'
1000.0000	NaN	0.4444	'linear'	NaN	'false'
1000.0000	0.4642	0.0096	'gaussian'	NaN	'false'
10.0000	0.4642	0.0027	'gaussian'	NaN	'false'
215.4435	0.4642	0.0007	'gaussian'	NaN	'false'
46.4159	0.4642	0.0007	'gaussian'	NaN	'false'
215.4435	0.4642	0.0344	'gaussian'	NaN	'false'
0.4642	0.0215	0.1237	'gaussian'	NaN	'false'
0.4642	0.0010	0.1237	'gaussian'	NaN	'false'
0.0046	NaN	0.1237	'polynomial'	3.0000	'true'
1000.0000	46.4159	0.0344	'gaussian'	NaN	'false'
1000.0000	0.1000	0.0344	'gaussian'	NaN	'true'
46.4159	0.1000	0.0027	'gaussian'	NaN	'true'
1000.0000	0.1000	0.0027	'gaussian'	NaN	'true'
215.4435	0.1000	0.0007	'gaussian'	NaN	'true'
10.0000	0.1000	0.0007	'gaussian'	NaN	'true'
10.0000	NaN	0.4444	'linear'	NaN	'true'
10.0000	NaN	0.4444	'linear'	NaN	'true'
10.0000	NaN	0.4444	'linear'	NaN	'true'
10.0000	NaN	0.4444	'linear'	NaN	'true'
1000.0000	0.4642	0.1237	'gaussian'	NaN	'false'
215.4435	0.4642	0.1237	'gaussian'	NaN	'false'
215.4435	0.4642	0.1237	'gaussian'	NaN	'false'
10.0000	0.4642	0.1237	'gaussian'	NaN	'false'
0.0010	NaN	0.4444	'linear'	NaN	'false'
0.0010	NaN	0.4444	'linear'	NaN	'false'
2.1544	0.0215	0.0096	'gaussian'	NaN	'true'
215.4435	0.1000	0.0096	'gaussian'	NaN	'false'
46.4159	0.1000	0.0096	'gaussian'	NaN	'false'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
46.4159	0.1000	0.0096	'gaussian'	NaN	'false'
10.0000	0.1000	0.0096	'gaussian'	NaN	'false'
215.4435	0.0215	0.0096	'gaussian'	NaN	'true'
215.4435	0.0215	0.0096	'gaussian'	NaN	'true'
46.4159	0.0215	0.0027	'gaussian'	NaN	'true'
46.4159	0.1000	0.0007	'gaussian'	NaN	'false'
215.4435	0.0215	0.0007	'gaussian'	NaN	'true'
2.1544	0.1000	0.0007	'gaussian'	NaN	'false'
2.1544	0.0215	0.0007	'gaussian'	NaN	'true'
10.0000	0.0215	0.0027	'gaussian'	NaN	'false'
0.0010	NaN	0.4444	'polynomial'	3.0000	'true'
0.0215	NaN	0.4444	'polynomial'	2.0000	'false'
2.1544	0.0215	0.0027	'gaussian'	NaN	'false'
2.1544	0.0010	0.0344	'gaussian'	NaN	'false'
215.4435	0.0046	0.0027	'gaussian'	NaN	'true'
10.0000	0.0046	0.0027	'gaussian'	NaN	'true'
10.0000	0.0046	0.0027	'gaussian'	NaN	'true'
1000.0000	0.0046	0.0007	'gaussian'	NaN	'true'
215.4435	0.0046	0.0007	'gaussian'	NaN	'true'
2.1544	0.0046	0.0027	'gaussian'	NaN	'true'
215.4435	0.0046	0.0344	'gaussian'	NaN	'true'
215.4435	0.0046	0.0344	'gaussian'	NaN	'true'
10.0000	0.0046	0.0344	'gaussian'	NaN	'true'
2.1544	0.0010	0.1237	'gaussian'	NaN	'false'
2.1544	0.0046	0.0007	'gaussian'	NaN	'true'
1000.0000	0.0046	0.0096	'gaussian'	NaN	'false'
1000.0000	0.0046	0.0096	'gaussian'	NaN	'false'
215.4435	0.0010	0.0096	'gaussian'	NaN	'true'
10.0000	0.0010	0.0096	'gaussian'	NaN	'true'
10.0000	0.1000	0.1237	'gaussian'	NaN	'true'
215.4435	0.0046	0.0027	'gaussian'	NaN	'false'
1000.0000	0.0046	0.0027	'gaussian'	NaN	'false'
46.4159	0.0010	0.0027	'gaussian'	NaN	'true'
46.4159	0.0010	0.0027	'gaussian'	NaN	'true'
10.0000	0.0010	0.0027	'gaussian'	NaN	'false'
46.4159	0.0046	0.0007	'gaussian'	NaN	'false'
46.4159	0.0010	0.0007	'gaussian'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
46.4159	0.0010	0.0007	'gaussian'	NaN	'false'
0.0010	NaN	5.7395	'linear'	NaN	'true'
0.0215	NaN	0.0027	'polynomial'	4.0000	'false'
0.4642	0.4642	74.1290	'gaussian'	NaN	'false'
10.0000	NaN	74.1290	'linear'	NaN	'false'
0.0046	NaN	5.7395	'polynomial'	3.0000	'false'
0.0010	0.0010	20.6268	'gaussian'	NaN	'true'
0.0215	NaN	0.0007	'polynomial'	3.0000	'false'
0.0010	0.0215	5.7395	'gaussian'	NaN	'false'
0.0046	0.0215	74.1290	'gaussian'	NaN	'true'
0.0215	NaN	20.6268	'polynomial'	3.0000	'true'
1000.0000	2.1544	20.6268	'gaussian'	NaN	'false'
46.4159	NaN	5.7395	'polynomial'	3.0000	'false'
1000.0000	46.4159	74.1290	'gaussian'	NaN	'false'
2.1544	NaN	5.7395	'linear'	NaN	'true'
0.0215	215.4435	74.1290	'gaussian'	NaN	'true'
2.1544	0.0215	5.7395	'gaussian'	NaN	'false'
10.0000	NaN	74.1290	'linear'	NaN	'true'
2.1544	NaN	20.6268	'polynomial'	2.0000	'false'
10.0000	NaN	5.7395	'polynomial'	3.0000	'false'
0.1000	NaN	5.7395	'polynomial'	2.0000	'false'
46.4159	NaN	0.0096	'polynomial'	3.0000	'false'

**Dalisodo**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
2.1544	0.4642	0.0007	'gaussian'	NaN	'true'
215.4435	0.1000	0.0007	'gaussian'	NaN	'true'
1,000.0000	0.1000	0.0007	'gaussian'	NaN	'true'
2.1544	0.1000	0.0007	'gaussian'	NaN	'false'
1,000.0000	0.1000	0.0027	'gaussian'	NaN	'true'
2.1544	0.1000	0.0027	'gaussian'	NaN	'true'
215.4435	0.1000	0.0027	'gaussian'	NaN	'false'
2.1544	0.0215	0.0007	'gaussian'	NaN	'true'
1,000.0000	0.0215	0.0007	'gaussian'	NaN	'true'
215.4435	0.1000	0.0096	'gaussian'	NaN	'false'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
2.1544	0.1000	0.0096	'gaussian'	NaN	'false'
2.1544	0.1000	0.0096	'gaussian'	NaN	'false'
2.1544	0.4642	0.0344	'gaussian'	NaN	'true'
1,000.0000	0.0215	0.0096	'gaussian'	NaN	'true'
2.1544	0.0215	0.0096	'gaussian'	NaN	'true'
46.4159	0.4642	0.0007	'gaussian'	NaN	'false'
1,000.0000	0.4642	0.0027	'gaussian'	NaN	'false'
10.0000	0.4642	0.0027	'gaussian'	NaN	'false'
1,000.0000	0.1000	0.0344	'gaussian'	NaN	'true'
2.1544	0.4642	0.0096	'gaussian'	NaN	'false'
1,000.0000	0.4642	0.0096	'gaussian'	NaN	'false'
0.4642	2.1544	0.0096	'gaussian'	NaN	'false'
215.4435	0.1000	0.0344	'gaussian'	NaN	'false'
215.4435	0.1000	0.0344	'gaussian'	NaN	'false'
2.1544	0.0215	0.0344	'gaussian'	NaN	'true'
0.4642	0.4642	0.1237	'gaussian'	NaN	'true'
215.4435	0.4642	0.0344	'gaussian'	NaN	'false'
10.0000	0.4642	0.0344	'gaussian'	NaN	'false'
10.0000	0.4642	0.0096	'gaussian'	NaN	'true'
0.4642	0.4642	0.0096	'gaussian'	NaN	'false'
10.0000	0.4642	0.0007	'gaussian'	NaN	'true'
0.4642	0.1000	0.0096	'gaussian'	NaN	'true'
215.4435	0.4642	0.0027	'gaussian'	NaN	'true'
1,000.0000	0.4642	0.0027	'gaussian'	NaN	'true'
0.4642	0.1000	0.0027	'gaussian'	NaN	'true'
0.4642	0.1000	0.0027	'gaussian'	NaN	'true'
0.4642	0.1000	0.0096	'gaussian'	NaN	'false'
0.4642	0.0215	0.0344	'gaussian'	NaN	'true'
46.4159	0.0215	0.0007	'gaussian'	NaN	'false'
46.4159	0.0215	0.0007	'gaussian'	NaN	'false'
1,000.0000	0.0215	0.0027	'gaussian'	NaN	'false'
215.4435	0.0215	0.0027	'gaussian'	NaN	'false'
2.1544	0.0215	0.0096	'gaussian'	NaN	'false'
10.0000	0.0215	0.0344	'gaussian'	NaN	'false'
0.4642	0.4642	0.1237	'gaussian'	NaN	'false'
0.1000	0.4642	0.0344	'gaussian'	NaN	'true'
1,000.0000	0.4642	0.1237	'gaussian'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
215.4435	0.4642	0.1237	'gaussian'	NaN	'true'
0.4642	0.0215	0.1237	'gaussian'	NaN	'true'
0.4642	0.0215	0.1237	'gaussian'	NaN	'true'
215.4435	0.0046	0.0007	'gaussian'	NaN	'true'
46.4159	0.0046	0.0007	'gaussian'	NaN	'true'
10.0000	0.0046	0.0007	'gaussian'	NaN	'true'
10.0000	0.0046	0.0007	'gaussian'	NaN	'true'
2.1544	0.0046	0.0027	'gaussian'	NaN	'true'
0.1000	0.4642	0.1237	'gaussian'	NaN	'true'
46.4159	0.1000	0.1237	'gaussian'	NaN	'true'
10.0000	0.1000	0.1237	'gaussian'	NaN	'false'
215.4435	0.1000	0.1237	'gaussian'	NaN	'false'
1,000.0000	0.1000	0.1237	'gaussian'	NaN	'false'
10.0000	0.0215	0.1237	'gaussian'	NaN	'true'
215.4435	0.0215	0.1237	'gaussian'	NaN	'true'
1,000.0000	0.0215	0.1237	'gaussian'	NaN	'true'
0.1000	0.4642	0.0007	'gaussian'	NaN	'true'
10.0000	NaN	0.1237	'polynomial'	2.0000	'true'
46.4159	NaN	0.1237	'polynomial'	2.0000	'true'
215.4435	NaN	0.1237	'polynomial'	2.0000	'true'
0.0215	NaN	0.1237	'polynomial'	2.0000	'true'
0.4642	0.0046	0.0344	'gaussian'	NaN	'true'
0.4642	NaN	0.1237	'polynomial'	2.0000	'true'
0.1000	NaN	0.1237	'polynomial'	2.0000	'true'
0.1000	2.1544	0.0027	'gaussian'	NaN	'false'
0.1000	0.4642	0.0096	'gaussian'	NaN	'false'
0.1000	0.4642	0.0096	'gaussian'	NaN	'false'
0.4642	2.1544	0.1237	'gaussian'	NaN	'true'
0.4642	0.0046	0.0007	'gaussian'	NaN	'true'
0.1000	0.0215	0.0344	'gaussian'	NaN	'false'
0.1000	0.0215	0.0344	'gaussian'	NaN	'false'
0.1000	0.0215	0.0096	'gaussian'	NaN	'true'
0.1000	0.4642	0.1237	'gaussian'	NaN	'false'
0.0215	0.4642	0.0344	'gaussian'	NaN	'true'
0.0215	0.4642	0.0344	'gaussian'	NaN	'true'
10.0000	10.0000	0.0344	'gaussian'	NaN	'false'
0.1000	0.1000	0.0027	'gaussian'	NaN	'false'



Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.0215	2.1544	0.0344	'gaussian'	NaN	'false'
0.1000	0.1000	0.0007	'gaussian'	NaN	'false'
0.0215	0.4642	0.0344	'gaussian'	NaN	'false'
215.4435	NaN	0.0344	'linear'	NaN	'true'
215.4435	NaN	0.0344	'linear'	NaN	'true'
215.4435	NaN	0.0344	'linear'	NaN	'true'
46.4159	NaN	0.0344	'polynomial'	2.0000	'true'
46.4159	NaN	0.0344	'polynomial'	2.0000	'true'
215.4435	NaN	0.0344	'polynomial'	2.0000	'true'
1,000.0000	NaN	0.0344	'polynomial'	2.0000	'true'
1,000.0000	NaN	0.1237	'linear'	NaN	'true'
1,000.0000	NaN	0.1237	'linear'	NaN	'true'
1,000.0000	NaN	0.1237	'linear'	NaN	'true'
1,000.0000	NaN	0.1237	'linear'	NaN	'true'
1,000.0000	NaN	0.1237	'linear'	NaN	'true'
1,000.0000	NaN	0.1237	'linear'	NaN	'true'

### Sumbermanjing Wetan

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
1000	NaN	0.034408	'linear'	NaN	'false'
1000	NaN	0.034408	'linear'	NaN	'false'
1000	NaN	0.034408	'linear'	NaN	'false'
0.021544	0.1	0.034408	'gaussian'	NaN	'false'
0.021544	0.021544	0.034408	'gaussian'	NaN	'true'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.464159	NaN	0.034408	'linear'	NaN	'false'
0.004642	0.1	0.034408	'gaussian'	NaN	'true'
0.004642	0.021544	0.034408	'gaussian'	NaN	'false'
0.004642	0.004642	0.034408	'gaussian'	NaN	'true'
0.1	0.1	0.034408	'gaussian'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
215.4435	NaN	0.034408	'linear'	NaN	'false'
215.4435	NaN	0.034408	'linear'	NaN	'false'
215.4435	NaN	0.034408	'linear'	NaN	'false'
215.4435	NaN	0.034408	'linear'	NaN	'false'
215.4435	NaN	0.034408	'linear'	NaN	'false'
0.1	0.021544	0.034408	'gaussian'	NaN	'false'
0.1	NaN	0.034408	'linear'	NaN	'false'
0.1	NaN	0.034408	'linear'	NaN	'false'
0.1	NaN	0.034408	'linear'	NaN	'false'
0.1	NaN	0.034408	'linear'	NaN	'false'
0.001	0.004642	0.034408	'gaussian'	NaN	'true'
2.154435	NaN	0.034408	'linear'	NaN	'false'
0.1	0.004642	0.034408	'gaussian'	NaN	'true'
10	NaN	0.034408	'linear'	NaN	'false'
10	NaN	0.034408	'linear'	NaN	'false'
10	NaN	0.034408	'linear'	NaN	'false'
10	NaN	0.034408	'linear'	NaN	'false'
2.154435	NaN	0.034408	'linear'	NaN	'true'
1000	NaN	0.034408	'linear'	NaN	'true'
1000	NaN	0.034408	'linear'	NaN	'true'
1000	NaN	0.034408	'linear'	NaN	'true'
1000	NaN	0.034408	'linear'	NaN	'true'
1000	NaN	0.034408	'linear'	NaN	'true'
0.021544	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'true'
46.41589	1000	0.034408	'gaussian'	NaN	'true'
0.464159	215.4435	0.034408	'gaussian'	NaN	'true'
0.001	46.41589	0.034408	'gaussian'	NaN	'true'
0.001	215.4435	0.034408	'gaussian'	NaN	'true'
0.004642	46.41589	0.034408	'gaussian'	NaN	'true'
0.004642	215.4435	0.034408	'gaussian'	NaN	'false'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.004642	215.4435	0.034408	'gaussian'	NaN	'false'
0.001	46.41589	0.034408	'gaussian'	NaN	'false'
215.4435	1000	0.034408	'gaussian'	NaN	'true'
10	215.4435	0.034408	'gaussian'	NaN	'true'
215.4435	NaN	0.034408	'linear'	NaN	'true'
215.4435	NaN	0.034408	'linear'	NaN	'true'
215.4435	NaN	0.034408	'linear'	NaN	'true'
10	NaN	0.034408	'linear'	NaN	'true'
10	NaN	0.034408	'linear'	NaN	'true'
10	NaN	0.034408	'linear'	NaN	'true'
10	NaN	0.034408	'linear'	NaN	'true'
0.1	46.41589	0.034408	'gaussian'	NaN	'true'
0.1	NaN	0.034408	'linear'	NaN	'true'
0.1	NaN	0.034408	'linear'	NaN	'true'
0.1	NaN	0.034408	'linear'	NaN	'true'
0.1	NaN	0.034408	'linear'	NaN	'true'
0.1	NaN	0.034408	'linear'	NaN	'true'
0.001	10	0.034408	'gaussian'	NaN	'true'
0.1	215.4435	0.034408	'gaussian'	NaN	'false'
1000	1000	0.034408	'gaussian'	NaN	'true'
46.41589	NaN	0.034408	'linear'	NaN	'true'
46.41589	NaN	0.034408	'linear'	NaN	'true'
46.41589	NaN	0.034408	'linear'	NaN	'true'
46.41589	NaN	0.034408	'linear'	NaN	'true'
46.41589	NaN	0.034408	'linear'	NaN	'true'
46.41589	NaN	0.034408	'linear'	NaN	'true'
10	1000	0.034408	'gaussian'	NaN	'false'
0.1	0.001	0.034408	'gaussian'	NaN	'false'
0.1	0.001	0.034408	'gaussian'	NaN	'false'
0.001	0.464159	0.034408	'gaussian'	NaN	'true'
0.001	2.154435	0.034408	'gaussian'	NaN	'true'
0.1	46.41589	0.034408	'gaussian'	NaN	'false'
1000	215.4435	0.034408	'gaussian'	NaN	'true'
0.464159	NaN	0.034408	'linear'	NaN	'true'
0.464159	NaN	0.034408	'linear'	NaN	'true'
1000	1000	0.034408	'gaussian'	NaN	'false'
1000	1000	0.034408	'gaussian'	NaN	'false'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
215.4435	1000	0.034408	'gaussian'	NaN	'false'
0.004642	10	0.034408	'gaussian'	NaN	'false'
46.41589	46.41589	0.034408	'gaussian'	NaN	'true'
0.021544	2.154435	0.034408	'gaussian'	NaN	'true'
0.001	NaN	0.034408	'linear'	NaN	'false'
0.001	NaN	0.034408	'linear'	NaN	'false'
0.001	NaN	0.034408	'linear'	NaN	'false'
0.001	NaN	0.034408	'linear'	NaN	'false'
215.4435	215.4435	0.034408	'gaussian'	NaN	'false'

### Pandansari

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.0046	NaN	0.1237	'polynomial'	3.0000	'true'
0.0046	NaN	0.1237	'polynomial'	3.0000	'true'
0.4642	0.4642	0.0344	'gaussian'	NaN	'false'
0.4642	0.1000	0.0344	'gaussian'	NaN	'false'
0.4642	0.0215	0.0344	'gaussian'	NaN	'true'
0.4642	0.0215	0.0344	'gaussian'	NaN	'false'
0.4642	0.0046	0.0344	'gaussian'	NaN	'false'
0.4642	0.0010	0.0344	'gaussian'	NaN	'true'
0.1000	0.4642	0.0344	'gaussian'	NaN	'false'
0.1000	0.0215	0.0344	'gaussian'	NaN	'true'
0.1000	0.0215	0.0344	'gaussian'	NaN	'false'
0.1000	0.0046	0.0344	'gaussian'	NaN	'true'
0.1000	0.0010	0.0344	'gaussian'	NaN	'false'
0.0215	0.4642	0.0344	'gaussian'	NaN	'false'
0.0215	0.1000	0.0344	'gaussian'	NaN	'false'
0.0046	0.0046	0.0344	'gaussian'	NaN	'true'
0.0046	0.0010	0.0344	'gaussian'	NaN	'true'
0.0046	0.0046	0.0344	'gaussian'	NaN	'false'
0.0010	NaN	0.0344	'linear'	NaN	'true'
0.4642	NaN	0.0344	'linear'	NaN	'false'
0.4642	NaN	0.0344	'linear'	NaN	'false'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
2.1544	NaN	0.0344	'linear'	NaN	'true'
2.1544	NaN	0.0344	'linear'	NaN	'true'
1000.0000	NaN	0.0344	'linear'	NaN	'true'
1000.0000	NaN	0.0344	'linear'	NaN	'true'
1000.0000	NaN	0.0344	'linear'	NaN	'true'
1000.0000	NaN	0.0344	'linear'	NaN	'true'
1000.0000	NaN	0.0344	'linear'	NaN	'true'
1000.0000	NaN	0.0344	'linear'	NaN	'true'
0.4642	NaN	0.0344	'linear'	NaN	'true'
0.4642	NaN	0.0344	'linear'	NaN	'true'
0.4642	NaN	0.0344	'linear'	NaN	'true'
46.4159	NaN	0.0344	'linear'	NaN	'false'
46.4159	NaN	0.0344	'linear'	NaN	'false'
46.4159	NaN	0.0344	'linear'	NaN	'false'
2.1544	215.4435	0.0344	'gaussian'	NaN	'false'
2.1544	215.4435	0.0344	'gaussian'	NaN	'false'
0.4642	215.4435	0.0344	'gaussian'	NaN	'false'
10.0000	NaN	0.0344	'linear'	NaN	'false'
10.0000	NaN	0.0344	'linear'	NaN	'false'
10.0000	NaN	0.0344	'linear'	NaN	'false'
46.4159	NaN	0.0344	'linear'	NaN	'true'
46.4159	NaN	0.0344	'linear'	NaN	'true'
46.4159	NaN	0.0344	'linear'	NaN	'true'
215.4435	1000.0000	0.0344	'gaussian'	NaN	'true'
0.0010	215.4435	0.0344	'gaussian'	NaN	'true'
0.0046	1000.0000	0.0344	'gaussian'	NaN	'false'
2.1544	1000.0000	0.0344	'gaussian'	NaN	'true'
2.1544	1000.0000	0.0344	'gaussian'	NaN	'true'
2.1544	215.4435	0.0344	'gaussian'	NaN	'true'
0.1000	1000.0000	0.0344	'gaussian'	NaN	'false'
10.0000	215.4435	0.0344	'gaussian'	NaN	'true'
0.0010	10.0000	0.0344	'gaussian'	NaN	'true'
0.1000	46.4159	0.0344	'gaussian'	NaN	'true'
0.0215	NaN	0.0344	'linear'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.0215	NaN	0.0344	'linear'	NaN	'true'
0.0215	NaN	0.0344	'linear'	NaN	'true'
0.0010	46.4159	0.0344	'gaussian'	NaN	'false'
0.0010	46.4159	0.0344	'gaussian'	NaN	'false'
2.1544	1000.0000	0.0344	'gaussian'	NaN	'false'
215.4435	215.4435	0.0344	'gaussian'	NaN	'true'
0.0046	NaN	0.0344	'linear'	NaN	'true'
0.0046	46.4159	0.0344	'gaussian'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
2.1544	NaN	0.0344	'linear'	NaN	'false'
0.1000	NaN	0.0344	'linear'	NaN	'true'
0.1000	NaN	0.0344	'linear'	NaN	'true'
0.1000	NaN	0.0344	'linear'	NaN	'true'
0.1000	NaN	0.0344	'linear'	NaN	'true'
1000.0000	215.4435	0.0344	'gaussian'	NaN	'true'
215.4435	NaN	0.0344	'linear'	NaN	'true'
215.4435	NaN	0.0344	'linear'	NaN	'true'
215.4435	NaN	0.0344	'linear'	NaN	'true'
10.0000	NaN	0.0344	'linear'	NaN	'true'
10.0000	NaN	0.0344	'linear'	NaN	'true'
46.4159	1000.0000	0.0344	'gaussian'	NaN	'false'
0.0010	10.0000	0.0344	'gaussian'	NaN	'false'
0.1000	10.0000	0.0344	'gaussian'	NaN	'true'
215.4435	1000.0000	0.0344	'gaussian'	NaN	'false'
0.0046	10.0000	0.0344	'gaussian'	NaN	'false'
0.0046	2.1544	0.0344	'gaussian'	NaN	'true'
46.4159	46.4159	0.0344	'gaussian'	NaN	'true'
46.4159	46.4159	0.0344	'gaussian'	NaN	'true'
215.4435	46.4159	0.0344	'gaussian'	NaN	'true'

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi
0.0010	NaN	0.0344	'linear'	NaN	'false'
0.1000	NaN	0.0344	'linear'	NaN	'false'
0.1000	NaN	0.0344	'linear'	NaN	'false'
0.1000	NaN	0.0344	'linear'	NaN	'false'
0.1000	NaN	0.0344	'linear'	NaN	'false'
2.1544	46.4159	0.0344	'gaussian'	NaN	'false'
0.0215	NaN	0.0344	'linear'	NaN	'false'
0.0215	2.1544	0.0344	'gaussian'	NaN	'true'
0.0046	NaN	0.0344	'linear'	NaN	'false'
0.0046	NaN	0.0344	'linear'	NaN	'false'
1000.0000	NaN	0.0344	'linear'	NaN	'false'

**Lampiran D**

Hasil dari Cross Validation

**Tambakrejo**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossvalid loss
46.4158	10	0.444392	'gaussian'	NaN	'true'	0.162293
2.1544	0.004642	0.034408	'gaussian'	NaN	'false'	0.513602
1000	215.4435	0.444392	'gaussian'	NaN	'false'	0.190991
0.001	10	0.444392	'gaussian'	NaN	'false'	0.521363
0.0215	1000	0.444392	'gaussian'	NaN	'false'	0.521594
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
0.0046	NaN	0.444392	'polynomial'	3	'true'	0.207989
0.001	NaN	0.444392	'polynomial'	3	'true'	0.210316
0.464	NaN	0.444392	'polynomial'	2	'true'	0.185909
1000	NaN	0.444392	'polynomial'	2	'true'	0.18338
10	NaN	0.444392	'polynomial'	2	'true'	0.182516
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
1000	NaN	0.444392	'linear'	NaN	'true'	0.170317
215.4434	NaN	0.444392	'linear'	NaN	'false'	0.170578
10	NaN	0.444392	'linear'	NaN	'false'	0.170836
46.4158	NaN	0.444392	'linear'	NaN	'false'	0.168488
0.02154	NaN	0.444392	'linear'	NaN	'true'	0.185317



**Sitirejo**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standar	Crossval loss
1000	0.4642	0.0027	'gaussian'	NaN	'true'	0.680347
46.4159	0.4642	0.0027	'gaussian'	NaN	'true'	0.676614
10	0.4642	0.0096	'gaussian'	NaN	'true'	0.561024
1000	0.4642	0.0096	'gaussian'	NaN	'true'	0.566746
10	0.4642	0.0344	'gaussian'	NaN	'true'	0.553531
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standar	Crossval loss
0.0046	NaN	0.1237	'polynomial'	3.0000	'true'	0.373601
0.0010	NaN	0.4444	'polynomial'	3.0000	'true'	0.835188
0.0215	NaN	0.4444	'polynomial'	2.0000	'false'	0.109597
0.0215	NaN	0.0027	'polynomial'	4.0000	'false'	0.641471
0.0046	NaN	5.7395	'polynomial'	3.0000	'false'	0.661754
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standar	Crossval loss
1000	NaN	0.4444	'linear'	NaN	'false'	0.079888
10	NaN	0.4444	'linear'	NaN	'true'	0.11705
0.0010	NaN	0.4444	'linear'	NaN	'false'	0.635608
0.0010	NaN	5.7395	'linear'	NaN	'true'	0.657344
10	NaN	74.1290	'linear'	NaN	'false'	0.644117

**Dalisodo**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
2.1544	0.4642	0.0007	'gaussian'	NaN	'true'	0.0585
215.4435	0.1000	0.0007	'gaussian'	NaN	'true'	0.0746
1000	0.1000	0.0007	'gaussian'	NaN	'true'	0.0702
2.1544	0.1000	0.0007	'gaussian'	NaN	false'	0.0610
1000	0.1000	0.0027	'gaussian'	NaN	'true'	0.0702
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
10	NaN	0.1237	'polynomial'	2.0000	'true'	0.021938
46.4159	NaN	0.1237	'polynomial'	2.0000	'true'	0.0233
215.4435	NaN	0.1237	'polynomial'	2.0000	'true'	0.025413
0.0215	NaN	0.1237	'polynomial'	2.0000	'true'	0.021547
0.4642	NaN	0.1237	'polynomial'	2.0000	'true'	0.026155
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
215.4435	NaN	0.0344	'linear'	NaN	'true'	0.001236
1,000	NaN	0.1237	'linear'	NaN	'true'	0.016018
46.4159	NaN	0.0344	'linear'	NaN	'true'	0.001266
0.0010	NaN	0.0344	'linear'	NaN	'true'	0.081034
2.1544	NaN	0.0344	'linear'	NaN	'true'	0.001255

**Sumbermanjing Wetan**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
0.0215	0.1	0.0344	'gaussian'	NaN	'false'	0.045504
0.0215	0.021544	0.0344	'gaussian'	NaN	'true'	0.045502
0.0046	0.1	0.0344	'gaussian'	NaN	'true'	0.045514
0.0046	0.021544	0.0344	'gaussian'	NaN	'false'	0.045555
0.0046	0.004642	0.0344	'gaussian'	NaN	'true'	0.045514
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
0.001	NaN	0.0344	'polynomial'	3	'true'	0.001815
0.0046	NaN	0.0344	'polynomial'	2	'true'	0.003071
0.0215	NaN	0.0344	'polynomial'	4	'false'	0.046233
0.4641	NaN	1.5970	'polynomial'	3	'true'	0.047997
0.0046	NaN	0.4443	'polynomial'	3	'false'	0.046233
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
1000	NaN	0.0344	'linear'	NaN	'false'	0.001184
0.4641	NaN	0.0344	'linear'	NaN	'false'	0.001186
215.4434	NaN	0.0344	'linear'	NaN	'false'	0.001184
0.1	NaN	0.0344	'linear'	NaN	'false'	0.033202
2.1544	NaN	0.0344	'linear'	NaN	'false'	0.001184

**Pandansari**

Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
0.4642	0.4642	0.0344	'gaussian'	NaN	'false'	0.0928335
0.4642	0.1000	0.0344	'gaussian'	NaN	'false'	0.0911377
0.4642	0.0215	0.0344	'gaussian'	NaN	'true'	0.090873
0.4642	0.0215	0.0344	'gaussian'	NaN	'false'	0.0902318
0.4642	0.0046	0.0344	'gaussian'	NaN	'false'	0.0903052
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
0.0046	NaN	0.1237	'polynomial'	3.0000	'true'	0.1619433
0.0046	NaN	0.0344	'polynomial'	2.0000	'true'	0.0416971
0.0010	NaN	0.1237	'polynomial'	3.0000	'true'	0.2041573
0.0046	NaN	0.0344	'polynomial'	3.0000	'true'	0.2786793
0.0215	NaN	0.0344	'polynomial'	2.0000	'true'	0.0367382
Box Constrain	Kernel Scale	Epsilon	Kernel	Polynomial Order	Standarisasi	Crossval loss
0.0010	NaN	0.0344	'linear'	NaN	'true'	0.0816305
0.4642	NaN	0.0344	'linear'	NaN	'false'	0.0009039
2.1544	NaN	0.0344	'linear'	NaN	'true'	0.0011821
1000	NaN	0.0344	'linear'	NaN	'true'	0.0012465
46.4159	NaN	0.0344	'linear'	NaN	'false'	0.0011353

## Lampiran E

Lampiran E merupakan Hasil dari Peramalan

**Tambakrejo**

Kernel Gaussian

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
1	Data	0				
2	Training	0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		1	0	1	100%	1
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	0	0	0%	0
10		0	0	0	0%	0
11		0	0	0	0%	0
12		2	0	2	100%	4
13		0	0	0	0%	0
14		1	0	1	100%	1
15		2	0	2	100%	4
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		2	0	2	100%	4
22		1	0	1	100%	1
23		3	0	3	100%	9
24		1	0	1	100%	1
25		0	0	0	0%	0
26		1	0	1	100%	1
27		0	1	1	100%	1
28		0	0	0	0%	0
29		2	0	2	100%	4
30		0	1	1	100%	1
31		2	1	1	33%	1
32		0	1	1	100%	1
33		0	0	0	0%	0

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
34		0	1	1	100%	1
35		0	1	1	100%	1
36		0	0	0	0%	0
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		1	0	1	100%	1
44		2	0	2	100%	4
45		0	0	0	0%	0
46		0	0	0	0%	0
47		1	0	1	100%	1
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	1	1	100%	1
51		0	1	1	100%	1
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	1	1	100%	1
55		2	0	2	100%	4
56		0	1	1	100%	1
57		0	0	0	0%	0
58		0	1	1	100%	1
59		0	0	0	0%	0
60		0	1	1	100%	1
61		0	1	1	100%	1
62		0	0	0	0%	0
63		1	0	1	100%	1
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	1	1	100%	1
68		2	0	2	100%	4
69		0	0	0	0%	0
70		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0
74		0	0	0	0%	0
75		0	1	1	100%	1
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	1	1	100%	1
79		0	1	1	100%	1
80		0	1	1	100%	1
81		0	1	1	100%	1
82		0	1	1	100%	1
83		2	1	1	33%	1
84		0	1	1	100%	1
85	Data Testing	0	1	1	100%	1
86		1	1	0	0%	0
87		0	1	1	100%	1
88		0	1	1	100%	1
89		0	0	0	0%	0
90		0	0	0	0%	0
91		2	0	2	100%	4
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		2	0	2	100%	4
97		2	0	2	100%	4
98		1	0	1	100%	1
99		0	1	1	100%	1
100		0	0	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	1	1	100%	1
104		0	1	1	100%	1

## Kernel Polynomial

No.	Time data	aktual	predict	Abs Error	SMAPE	SE
1	Data	0				
2	Training	0	1	1	100%	1
3		0	1	1	100%	1
4		0	1	1	100%	1
5		1	0	1	100%	1
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	0	0	0%	0
10		0	0	0	0%	0
11		0	0	0	0%	0
12		2	0	2	100%	4
13		0	0	0	0%	0
14		1	0	1	100%	1
15		2	1	1	33%	1
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	1	1	100%	1
21		2	1	1	33%	1
22		1	0	1	100%	1
23		3	0	3	100%	9
24		1	0	1	100%	1
25		0	0	0	0%	0
26		1	0	1	100%	1
27		0	0	0	0%	0
28		0	0	0	0%	0
29		2	0	2	100%	4
30		0	1	1	100%	1
31		2	0	2	100%	4
32		0	1	1	100%	1
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0



No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		1	0	1	100%	1
44		2	0	2	100%	4
45		0	0	0	0%	0
46		0	0	0	0%	0
47		1	0	1	100%	1
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	1	1	100%	1
52		0	1	1	100%	1
53		0	0	0	0%	0
54		0	0	0	0%	0
55		2	1	1	33%	1
56		0	1	1	100%	1
57		0	0	0	0%	0
58		0	0	0	0%	0
59		0	0	0	0%	0
60		0	0	0	0%	0
61		0	0	0	0%	0
62		0	0	0	0%	0
63		1	0	1	100%	1
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		2	0	2	100%	4
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	1	1	100%	1
82		0	1	1	100%	1
83		2	0	2	100%	4
84		0	2	2	100%	4
85	Data Testing	0	1	1	100%	1
86		1	0	1	100%	1
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		2	1	1	33%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		2	0	2	100%	4
97		2	0	2	100%	4
98		1	1	0	0%	0
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	1	1	100%	1

Kernel Linear

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	0				
2		0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		1	0	1	100%	1
6		0	1	1	100%	1
7		0	1	1	100%	1
8		0	0	0	0%	0
9		0	2	2	100%	4
10		0	1	1	100%	1
11		0	0	0	0%	0
12		2	0	2	100%	4
13		0	0	0	0%	0
14		1	0	1	100%	1
15		2	0	2	100%	4
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	1	1	100%	1
21		2	0	2	100%	4
22		1	0	1	100%	1
23		3	1	2	50%	4
24		1	0	1	100%	1
25		0	0	0	0%	0
26		1	0	1	100%	1
27		0	1	1	100%	1
28		0	1	1	100%	1
29		2	0	2	100%	4
30		0	0	0	0%	0
31		2	1	1	33%	1
32		0	1	1	100%	1
33		0	0	0	0%	0
34		0	1	1	100%	1
35		0	1	1	100%	1
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	1	1	100%	1
41		0	0	0	0%	0
42		0	1	1	100%	1
43		1	0	1	100%	1
44		2	1	1	33%	1
45		0	0	0	0%	0
46		0	1	1	100%	1
47		1	1	0	0%	0
48		0	1	1	100%	1
49		0	1	1	100%	1
50		0	1	1	100%	1
51		0	1	1	100%	1
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	0	0	0%	0
55		2	1	1	33%	1
56		0	1	1	100%	1
57		0	1	1	100%	1
58		0	1	1	100%	1
59		0	0	0	0%	0
60		0	1	1	100%	1
61		0	0	0	0%	0
62		0	1	1	100%	1
63		1	1	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	2	2	100%	4
67		0	1	1	100%	1
68		2	0	2	100%	4
69		0	0	0	0%	0
70		0	1	1	100%	1
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	1	1	100%	1
83		2	1	1	33%	1
84		0	1	1	100%	1
85	Data Testing	0	0	0	0%	0
86		1	1	0	0%	0
87		0	1	1	100%	1
88		0	1	1	100%	1
89		0	0	0	0%	0
90		0	0	0	0%	0
91		2	1	1	33%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		2	0	2	100%	4
97		2	0	2	100%	4
98		1	0	1	100%	1
99		0	1	1	100%	1
100		0	1	1	100%	1
101		0	2	2	100%	4
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	1	1	100%	1

**Sitirejo****Kernel Gaussian**

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
1	Data	1				
2	Training	3	1	2	50%	4
3		0	3	3	100%	9
4		0	1	1	100%	1
5		0	0	0	0%	0
6		1	0	1	100%	1
7		1	1	0	0%	0
8		1	1	0	0%	0
9		5	0	5	100%	25
10		3	0	3	100%	9
11		2	3	1	20%	1
12		0	2	2	100%	4
13		1	0	1	100%	1
14		0	1	1	100%	1
15		0	0	0	0%	0
16		0	0	0	0%	0
17		1	0	1	100%	1
18		0	1	1	100%	1
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		1	0	1	100%	1
25		0	0	0	0%	0
26		1	0	1	100%	1
27		0	1	1	100%	1
28		0	0	0	0%	0
29		0	0	0	0%	0
30		2	0	2	100%	4
31		0	2	2	100%	4
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
36		0	0	0	0%	0
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	0	0	0%	0
44		1	0	1	100%	1
45		0	1	1	100%	1
46		0	0	0	0%	0
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	0	0	0%	0
55		0	0	0	0%	0
56		0	0	0	0%	0
57		0	0	0	0%	0
58		0	0	0	0%	0
59		1	0	1	100%	1
60		0	1	1	100%	1
61		0	0	0	0%	0
62		0	0	0	0%	0
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
73		0	0	0	0%	0
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		1	0	1	100%	1
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		1	0	1	100%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		2	0	2	100%	4
98		0	1	1	100%	1
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	1	1	100%	1
102		0	1	1	100%	1
103		0	0	0	0%	0
104		0	0	0	0%	0



## Kernel Polynomial

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	1				
2		3	0	3	100%	9
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		1	1	0	0%	0
7		1	1	0	0%	0
8		1	0	1	100%	1
9		5	1	4	67%	16
10		3	1	2	50%	4
11		2	1	1	33%	1
12		0	0	0	0%	0
13		1	0	1	100%	1
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		1	0	1	100%	1
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		1	0	1	100%	1
25		0	0	0	0%	0
26		1	0	1	100%	1
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		2	0	2	100%	4
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	0	0	0%	0
44		1	0	1	100%	1
45		0	0	0	0%	0
46		0	0	0	0%	0
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	1	1	100%	1
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	0	0	0%	0
55		0	0	0	0%	0
56		0	0	0	0%	0
57		0	0	0	0%	0
58		0	0	0	0%	0
59		1	0	1	100%	1
60		0	0	0	0%	0
61		0	0	0	0%	0
62		0	0	0	0%	0
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		1	0	1	100%	1
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		1	0	1	100%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		2	0	2	100%	4
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	1	1	100%	1
101		0	1	1	100%	1
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

## Kernel Linear

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
1	Data	1				
2	Training	3	0	3	100%	9
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		1	1	0	0%	0
7		1	1	0	0%	0
8		1	0	1	100%	1
9		5	1	4	67%	16
10		3	1	2	50%	4
11		2	0	2	100%	4
12		0	0	0	0%	0
13		1	0	1	100%	1
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		1	0	1	100%	1
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	1	1	100%	1
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		1	0	1	100%	1
25		0	0	0	0%	0
26		1	0	1	100%	1
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		2	0	2	100%	4
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
36		0	0	0	0%	0
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	1	1	100%	1
43		0	0	0	0%	0
44		1	0	1	100%	1
45		0	0	0	0%	0
46		0	1	1	100%	1
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	1	1	100%	1
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	0	0	0%	0
55		0	1	1	100%	1
56		0	0	0	0%	0
57		0	1	1	100%	1
58		0	1	1	100%	1
59		1	0	1	100%	1
60		0	0	0	0%	0
61		0	0	0	0%	0
62		0	1	1	100%	1
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	1	1	100%	1
67		0	1	1	100%	1
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
73		0	0	0	0%	0
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		1	0	1	100%	1
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		1	0	1	100%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		2	0	2	100%	4
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	1	1	100%	1
101		0	1	1	100%	1
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

**Dalisodo**  
Kernel Gaussian

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	0				
2		0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	0	0	0%	0
10		0	0	0	0%	0
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
36		0	0	0	0%	0
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	0	0	0%	0
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	1	1	100%	1
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	1	1	100%	1
52		0	0	0	0%	0
53		1	0	1	100%	1
54		2	1	1	33%	1
55		1	0	1	100%	1
56		0	0	0	0%	0
57		0	0	0	0%	0
58		0	0	0	0%	0
59		0	0	0	0%	0
60		1	0	1	100%	1
61		0	1	1	100%	1
62		0	0	0	0%	0
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0



No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
73		0	0	0	0%	0
74		1	0	1	100%	1
75		0	1	1	100%	1
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		0	0	0	0%	0
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		1	0	1	100%	1
91		1	0	1	100%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		1	0	1	100%	1
98		0	0	0	0%	0
99		0	0	0	0%	0
100		1	1	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

## Kernel Polynomial

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
1	Data	0				
2	Training	0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	1	1	100%	1
7		0	1	1	100%	1
8		0	0	0	0%	0
9		0	1	1	100%	1
10		0	1	1	100%	1
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	1	1	100%	1
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	1	1	100%	1
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	1	1	100%	1
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	1	1	100%	1
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		1	0	1	100%	1
54		2	0	2	100%	4
55		1	0	1	100%	1
56		0	0	0	0%	0
57		0	1	1	100%	1
58		0	0	0	0%	0
59		0	0	0	0%	0
60		1	0	1	100%	1
61		0	0	0	0%	0
62		0	0	0	0%	0
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	1	1	100%	1
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
74		1	0	1	100%	1
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		0	0	0	0%	0
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		1	0	1	100%	1
91		1	0	1	100%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		1	0	1	100%	1
98		0	0	0	0%	0
99		0	0	0	0%	0
100		1	1	0	0%	0
101		0	1	1	100%	1
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

## Kernel Linear

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	0				
2		0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	1	1	100%	1
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	1	1	100%	1
10		0	1	1	100%	1
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	1	1	100%	1
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	1	1	100%	1
29		0	0	0	0%	0
30		0	1	1	100%	1
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0

37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	1	1	100%	1
43		0	0	0	0%	0
44		0	1	1	100%	1
45		0	0	0	0%	0
46		0	1	1	100%	1
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	1	1	100%	1
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	1	1	100%	1
53		1	1	0	0%	0
54		2	0	2	100%	4
55		1	1	0	0%	0
56		0	0	0	0%	0
57		0	1	1	100%	1
58		0	0	0	0%	0
59		0	1	1	100%	1
60		1	0	1	100%	1
61		0	0	0	0%	0
62		0	1	1	100%	1
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	1	1	100%	1
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0
74		1	0	1	100%	1
75		0	0	0	0%	0

76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	1	1	100%	1
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85		0	0	0	0%	0
86	Data Testing	0	0	0	0%	0
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		1	0	1	100%	1
91		1	0	1	100%	1
92		0	0	0	0%	0
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		1	0	1	100%	1
98		0	0	0	0%	0
99		0	0	0	0%	0
100		1	1	0	0%	0
101		0	1	1	100%	1
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

**Sumbermanjing Wetan****Kernel Gaussian**

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
1	Data	0				
2	Training	0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	0	0	0%	0
10		0	0	0	0%	0
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	1	1	100%	1



No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
36		0	0	0	0%	0
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	0	0	0%	0
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	0	0	0%	0
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		1	0	1	100%	1
55		0	0	0	0%	0
56		0	0	0	0%	0
57		0	0	0	0%	0
58		0	0	0	0%	0
59		0	0	0	0%	0
60		0	0	0	0%	0
61		0	0	0	0%	0
62		0	0	0	0%	0
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		1	0	1	100%	1
71		0	1	1	100%	1
72		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
73		0	0	0	0%	0
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		1	0	1	100%	1
78		0	0	0	0%	0
79		0	1	1	100%	1
80		0	0	0	0%	0
81		1	0	1	100%	1
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		1	1	0	0%	0
87		0	1	1	100%	1
88		0	1	1	100%	1
89		0	0	0	0%	0
90		1	0	1	100%	1
91		0	1	1	100%	1
92		1	0	1	100%	1
93		0	0	0	0%	0
94		0	0	0	0%	0
95		2	0	2	100%	4
96		1	0	1	100%	1
97		0	0	0	0%	0
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

## Kernel Polynomial

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	0				
2		0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	1	1	100%	1
10		0	1	1	100%	1
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	0	0	0%	0
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	0	0	0%	0
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		1	0	1	100%	1
55		0	0	0	0%	0
56		0	0	0	0%	0
57		0	0	0	0%	0
58		0	0	0	0%	0
59		0	0	0	0%	0
60		0	0	0	0%	0
61		0	0	0	0%	0
62		0	0	0	0%	0
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	1	1	100%	1
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		1	0	1	100%	1
71		0	0	0	0%	0
72		0	0	0	0%	0
73		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		1	0	1	100%	1
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		1	0	1	100%	1
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		1	0	1	100%	1
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		1	0	1	100%	1
91		0	0	0	0%	0
92		1	0	1	100%	1
93		0	0	0	0%	0
94		0	0	0	0%	0
95		2	0	2	100%	4
96		1	0	1	100%	1
97		0	0	0	0%	0
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	1	1	100%	1
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0

## Kernel Linear

No.	Time data	aktual	predict	Abs Error	SMAPE	SE
1	Data	0				
2	Training	0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	1	1	100%	1
10		0	1	1	100%	1
11		0	1	1	100%	1
12		0	1	1	100%	1
13		0	1	1	100%	1
14		0	1	1	100%	1
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	1	1	100%	1
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	1	1	100%	1
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	1	1	100%	1
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	1	1	100%	1
35		0	1	1	100%	1
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	1	1	100%	1
43		0	0	0	0%	0
44		0	0	0	0%	0
45		0	1	1	100%	1
46		0	1	1	100%	1
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	1	1	100%	1
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	1	1	100%	1
54		1	0	1	100%	1
55		0	0	0	0%	0
56		0	0	0	0%	0
57		0	1	1	100%	1
58		0	0	0	0%	0
59		0	1	1	100%	1
60		0	0	0	0%	0
61		0	0	0	0%	0
62		0	1	1	100%	1
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	1	1	100%	1
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		1	0	1	100%	1
71		0	1	1	100%	1
72		0	0	0	0%	0
73		0	1	1	100%	1

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
74		0	1	1	100%	1
75		0	0	0	0%	0
76		0	0	0	0%	0
77		1	0	1	100%	1
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		1	0	1	100%	1
82		0	0	0	0%	0
83		0	1	1	100%	1
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		1	1	0	0%	0
87		0	1	1	100%	1
88		0	1	1	100%	1
89		0	1	1	100%	1
90		1	0	1	100%	1
91		0	1	1	100%	1
92		1	0	1	100%	1
93		0	0	0	0%	0
94		0	0	0	0%	0
95		2	0	2	100%	4
96		1	0	1	100%	1
97		0	0	0	0%	0
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	1	1	100%	1
101		0	1	1	100%	1
102		0	0	0	0%	0
103		0	0	0	0%	0
104		0	0	0	0%	0



**Pandansari**  
Kernel Gaussian

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	0				
2		0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	0	0	0%	0
10		0	0	0	0%	0
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
36		0	0	0	0%	0
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	0	0	0%	0
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	0	0	0%	0
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	0	0	0%	0
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	0	0	0%	0
55		0	0	0	0%	0
56		1	0	1	100%	1
57		0	1	1	100%	1
58		2	0	2	100%	4
59		1	1	0	0%	0
60		0	1	1	100%	1
61		0	0	0	0%	0
62		1	0	1	100%	1
63		0	1	1	100%	1
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		1	0	1	100%	1
72		0	1	1	100%	1

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
73		0	0	0	0%	0
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		0	0	0	0%	0
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		0	0	0	0%	0
92		1	0	1	100%	1
93		0	1	1	100%	1
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		0	1	1	100%	1
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	0	0	0%	0
104		1	0	1	100%	1

## Kernel Polynomial

No.	Time data	aktual	predict	Abs Error	SMAPE	SE
1	Data	0				
2	Training	0	0	0	0%	0
3		0	0	0	0%	0
4		0	0	0	0%	0
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	0	0	0%	0
8		0	0	0	0%	0
9		0	0	0	0%	0
10		0	0	0	0%	0
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	0	0	0%	0
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	0	0	0%	0
27		0	0	0	0%	0
28		0	0	0	0%	0
29		0	0	0	0%	0
30		0	0	0	0%	0
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	1	1	100%	1
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	0	0	0%	0
43		0	1	1	100%	1
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	0	0	0%	0
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	0	0	0%	0
51		0	0	0	0%	0
52		0	0	0	0%	0
53		0	0	0	0%	0
54		0	0	0	0%	0
55		0	0	0	0%	0
56		1	0	1	100%	1
57		0	0	0	0%	0
58		2	0	2	100%	4
59		1	0	1	100%	1
60		0	0	0	0%	0
61		0	0	0	0%	0
62		1	0	1	100%	1
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	0	0	0%	0
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		1	0	1	100%	1
72		0	0	0	0%	0
73		0	1	1	100%	1

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
74		0	0	0	0%	0
75		0	0	0	0%	0
76		0	0	0	0%	0
77		0	0	0	0%	0
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	0	0	0%	0
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	0	0	0%	0
85	Data Testing	0	0	0	0%	0
86		0	0	0	0%	0
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		0	1	1	100%	1
92		1	0	1	100%	1
93		0	0	0	0%	0
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		0	0	0	0%	0
98		0	0	0	0%	0
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	0	0	0%	0
104		1	0	1	100%	1

## Kernel Linear

No.	Type data	aktual	predict	Abs Error	SMAPE	SE
1	Data Training	0				
2		0	0	0	0%	0
3		0	0	0	0%	0
4		0	1	1	100%	1
5		0	0	0	0%	0
6		0	0	0	0%	0
7		0	1	1	100%	1
8		0	0	0	0%	0
9		0	1	1	100%	1
10		0	1	1	100%	1
11		0	0	0	0%	0
12		0	0	0	0%	0
13		0	1	1	100%	1
14		0	0	0	0%	0
15		0	0	0	0%	0
16		0	0	0	0%	0
17		0	0	0	0%	0
18		0	0	0	0%	0
19		0	0	0	0%	0
20		0	0	0	0%	0
21		0	0	0	0%	0
22		0	0	0	0%	0
23		0	0	0	0%	0
24		0	0	0	0%	0
25		0	0	0	0%	0
26		0	1	1	100%	1
27		0	0	0	0%	0
28		0	1	1	100%	1
29		0	0	0	0%	0
30		0	1	1	100%	1
31		0	0	0	0%	0
32		0	0	0	0%	0
33		0	0	0	0%	0
34		0	0	0	0%	0
35		0	0	0	0%	0
36		0	0	0	0%	0

No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
37		0	0	0	0%	0
38		0	0	0	0%	0
39		0	1	1	100%	1
40		0	0	0	0%	0
41		0	0	0	0%	0
42		0	1	1	100%	1
43		0	1	1	100%	1
44		0	0	0	0%	0
45		0	0	0	0%	0
46		0	1	1	100%	1
47		0	0	0	0%	0
48		0	0	0	0%	0
49		0	0	0	0%	0
50		0	1	1	100%	1
51		0	1	1	100%	1
52		0	1	1	100%	1
53		0	1	1	100%	1
54		0	1	1	100%	1
55		0	0	0	0%	0
56		1	1	0	0%	0
57		0	0	0	0%	0
58		2	0	2	100%	4
59		1	1	0	0%	0
60		0	0	0	0%	0
61		0	1	1	100%	1
62		1	0	1	100%	1
63		0	0	0	0%	0
64		0	0	0	0%	0
65		0	0	0	0%	0
66		0	1	1	100%	1
67		0	0	0	0%	0
68		0	0	0	0%	0
69		0	0	0	0%	0
70		0	0	0	0%	0
71		1	1	0	0%	0
72		0	0	0	0%	0
73		0	1	1	100%	1



No.	Tipe data	aktual	predict	Abs Error	SMAPE	SE
74		0	1	1	100%	1
75		0	1	1	100%	1
76		0	0	0	0%	0
77		0	1	1	100%	1
78		0	0	0	0%	0
79		0	0	0	0%	0
80		0	0	0	0%	0
81		0	1	1	100%	1
82		0	0	0	0%	0
83		0	0	0	0%	0
84		0	1	1	100%	1
85	Data Testing	0	1	1	100%	1
86		0	0	0	0%	0
87		0	0	0	0%	0
88		0	0	0	0%	0
89		0	0	0	0%	0
90		0	0	0	0%	0
91		0	1	1	100%	1
92		1	0	1	100%	1
93		0	1	1	100%	1
94		0	0	0	0%	0
95		0	0	0	0%	0
96		1	0	1	100%	1
97		0	1	1	100%	1
98		0	1	1	100%	1
99		0	0	0	0%	0
100		0	0	0	0%	0
101		0	0	0	0%	0
102		0	0	0	0%	0
103		0	1	1	100%	1
104		1	1	0	0%	0

